UNAPRIJEDENI DVOSLOJNI ADAPTIVNI SUSTAV UPRAVLJANJA ENERGIJOM ZA KRATKOROˇCNO PLANIRANJE POGONA MIKROMREˇZE

Žnidarec, Matej

Doctoral thesis / Disertacija

2022

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:396272

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-25**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

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

Matej Žnidarec

UNAPRIJEĐENI DVOSLOJNI ADAPTIVNI SUSTAV UPRAVLJANJA ENERGIJOM ZA KRATKOROČNO PLANIRANJE POGONA MIKROMREŽE

Doktorska disertacija

Osijek, 2022.

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

Mentor: prof. dr. sc. Damir Šljivac

Disertacija ima 203 stranice
Disertacija broj 86

Sadržaj

Stranica

1 Uvod **1**

1.1 Organizacija i struktura doktorske disertacije 3

2 Istraživanja u području sustava upravljanja energijom mikromreža . . . **5**

2.1 Upravljački sustav mikromreže 6

2.2 Sustav upravljanja energijom mikromreže 7

2.3 Vrsta i elementi mikromreže 9

2.3.1 Izvori električne energije 10

2.3.2 Trošila električne energije 11

2.3.3 Sustavi pohrane električne energije 12

2.4 Tržišno okruženje mikromreže 14

2.5 Predviđanje ulaznih parametara u optimizacijske probleme 16

2.6 Optimizacijski okvir i optimizacijski problemi sustava upravljanja energijom 19

2.6.1 Optimizacijski okviri 19

2.6.2 Optimizacijska metoda 21

2.6.3 Funkcije cilja i ograničenja 23

2.7 Višeslojni sustavi upravljanja energijom mikromreža 25

3 Unaprijeđeni dvoslojni adaptivni sustav upravljanja energijom mikromreže 29

3.1 Područje i strategija istraživanja 29

3.2 Optimizacijski okvir sustava upravljanja energijom mikromreže 33

3.3 Optimizacijska metoda primijenjena u optimizacijskom problemu višeg sloja sustava upravljanja energijom mikromreže 36

3.3.1 Mješovito cjelobrojno linearno programiranje 37

3.4 Optimizacijska metoda primijenjena u optimizacijskom problemu nižeg sloja sustava upravljanja energijom mikromreže 39

3.4.1 Optimizacija rojem čestica 41

3.4.2 Simulacijski alat za modeliranje i analizu elektroenergetskih mreža *OpenDSS* . . . 43

4 Optimizacijski problemi dvoslojnog sustava upravljanja energijom mikromreže . . . 45

4.1 Mreža (mjesto priključka mikromreže na nadređenu elektroenergetsku mrežu) 46

4.2 Baterijski sustav pohrane energije . . . 50

4.2.1 Dvosmjerni pretvarač energetske elektronike . . . 50

4.2.2 Model litij-ionske baterije . . . 54

4.2.3 Degradacija baterijskog sustava pohrane energije . . . 59

4.2.4 Vrijednost pohranjene energije baterijskog sustava pohrane energije . 65

4.3 Fotonaponski sustav . . . 66

4.4 Upravljivi generator . . . 68

4.5 Trošila električne energije . . . 71

4.5.1 Statički upravljiva trošila . . . 72

4.5.2 Dinamički upravljiva trošila . . . 73

4.5.3 Vremenski odgodivo trošilo . . . 74

4.6 Funkcija cilja . . . 75

4.7 Optimizacijski problem nižeg sloja sustava upravljanja energijom mikromreže 77

4.7.1 Dodatna ograničenja optimizacijskog problema . . . 78

4.7.2 Funkcija cilja . . . 80

4.8 Predviđanje ulaznih parametara u optimizacijske probleme . . . 86

4.8.1 Metode predviđanja ulaznih parametara u optimizacijski problem višeg sloja sustava upravljanja energijom . . . 86

4.8.2 Metode predviđanja ulaznih parametara u optimizacijski problem nižeg sloja sustava upravljanja energijom . . . 91

5 Vrednovanje unaprijeđenog dvoslojnog sustava upravljanja energijom planiranjem kratkoročnog pogona testne mikromreže . . . 93

5.1 Postavke optimizacijskog okvira i optimizacijskih metoda . . . 93

5.2 Opis testne mikromreže . . . 94

5.2.1 Tehničke karakteristike elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu) za referentni slučaj . . . 95

5.2.2 Model testne mikromreže u *IEEE European Low Voltage Test Feeder* testnom sustavu za referentni slučaj . . . 101

5.2.3 Tehničke karakteristike baterijskog sustava pohrane energije za referentni slučaj . . . 102

5.2.4 Tehničke karakteristike fotonaponskog sustava za referentni slučaj . . 107
5.2.5 Tehničke karakteristike upravljivog generatora 110
5.2.6 Tehničke karakteristike trošila električne energije za referentni slučaj . 112
5.3 Treniranje i testiranje umjetnih neuronskih mreža s dugom kratkoročnom memorijom 116
5.3.1 Rezultati treniranja i testiranja umjetne neuronske mreže za predviđanje snage potrošnje električne energije mikromreže u višem sloju 120
5.3.2 Rezultati treniranja i testiranja umjetnih neuronskih mreža za predviđanje ulaznih parametara u optimizacijski problem nižeg sloja 126
5.4 Rezultati kratkoročnog planiranja pogona testne mikromreže 133
5.4.1 Utjecaj dodatnih (virtualnih) prihoda/troškova funkcije cilja višeg sloja sustava upravljanja energijom na kratkoročno planiranje pogona testne mikromreže 133
5.4.2 Utjecaj optimizacijskog okvira na kratkoročno planiranje pogona testne mikromreže 145
5.4.3 Analiza osjetljivosti funkcije cilja optimizacijskog problema višeg sloja sustava upravljanja energijom na postavke elemenata testne mikromreže 157

6 Zaključak 165

Literatura 168

Popis slika 181

Popis tablica 186

Popis kratica 188

Prilozi 190

Sažetak 201

Abstract 202

Životopis 203

1. Uvod

Duboko ukorijenjena ovisnost čovječanstva o energiji rezultira kontinuiranim porastom potrošnje krajnje energije. Električnu energiju karakterizira mogućnost pretvorbe u razne korisne oblike energije potrebne za sve djelatnosti čovjeka. Usprkos svim poticajnim politikama koje promoviraju energetsku učinkovitost, globalna potražnja za krajnjom energijom je od 2009. do 2019. rasla za oko 1.8 % godišnje dok je električna energija sudjelovala s udjelom od 17 % u ukupnoj potrošnji krajnje energije u 2018. godini. Ukupno 27 % potražnje za električnom energijom zadovoljilo se iz postrojenja na obnovljive izvore energije. Ukupna instalirana snaga postrojenja za proizvodnju električne energije iz obnovljivih izvora povećala se samo u 2019. godini za 257 GW, s udjelom povećanja fotonaponskih sustava od 139 GW odnosno oko 54 % [1].

Stimulativne politike i poticaji rezultirale su velikim porastom instalirane snage postrojenja za proizvodnju električne energije iz obnovljivih izvora i velikim padom investicijskih troškova. Kako se većina ovih postrojenja (brojčano) integrira u distribucijsku elektroenergetsku mrežu (tzv. distribuirani izvori), dosadašnji koncept proizvodnje električne energije iz velikih proizvodnih jedinica spojenih na prijenosnu mrežu i distribuiranje te energije putem prijenosnog odnosno distribucijskog sustava do krajnjih potrošača se mijenja. Pretvaranje pasivnih distribucijskih mreža u aktivne donosi nove izazove u vođenju elektroenergetskog sustava koji ovise o razini integracije distribuirane proizvodnje. Integracija ima pozitivne učinke kao što su smanjenje opterećenja mreže i smanjeni gubici energije, no iznad određene razine može prouzročiti probleme s kvalitetom električne energije (posebice s regulacijom napona), povećavaju se iznosi struja kratkih spojeva, narušava se dinamička stabilnost sustava, a kao rezultat nepredvidljive proizvodnje iz obnovljivih izvora energije mogu se javiti i teškoće kod regulacije djelatne i jalove snage.

Kao odgovor na ove izazove u znanstvenoj literaturi javlja se novi koncept napredne (pametne) elektroenergetske mreže koja se temelji na informacijsko-komunikacijskim tehnologijama (ICT), a čija je zadaća učinkovito opskrbiti potražnju korisnika s lokalnom proizvodnjom električne energije, pritom omogućujući dodatne usluge i obostrano sudjelovanje u ovom procesu u stvarnom vremenu. Jedna od temeljnih sastavnica napredne elektroenergetske mreže su i mikromreže [2].

Elektroenergetske mreže za napajanje određenog broja lokalnih potrošača postoje od samih početaka razvoja elektroenergetskog sustava u zadnjim godinama 19. stoljeća iako nisu bile izričito definirane pod pojmom mikromreže. Ne postoji jednoznačna definicija mikromreže, stoga se u literaturi mogu pronaći različite formulacije. Jedna od najkorištenijih definicija u literaturi je definicija Ministarstva energetike SAD-a [3]: *„Mikromreža je grupa međusobno povezanih potrošača i distribuiranih izvora energije s jasno definiranim električnim ograničenjima koja se ponaša kao jedna upravljiva cjelina u odnosu na elektroenergetski sustav. Mikromreža se može povezati ili odvojiti od nadređene elektroenergetske mreže što joj omogućuje paralelni rad s nadređenom mrežom ili otočni način rada“*. Nadalje, autor u [2] definira mikromrežu kao: *„Mikromreža sadržava niskonaponsku distribucijsku mrežu zajedno s distribuiranim izvorima energije (mikroturbine, gorivne ćelije, fotonapon i dr.), sustavima pohrane energije (zamašnjaci, energetski kondenzatori i baterije) i upravljivim trošilima. Takvim sustavom može se upravljati zavisno o nadređenoj elektroenergetskoj mreži, ako je spojen na nju, ili nezavisno od nadređene elektroenergetske mreže u slučaju odvajanja od nje. Ako se njima upravlja učinkovito i koordinirano, pogon mikroizvora može pružiti različite dobrobiti cjelokupnom sustavu“*. Danas se mikromreže mogu naći u raznim izvedbama, mikromreže sveučilišnih kampusa, vojnih baza, mikromreža određene zajednice kućanstava (dio distribucijske elektroenergetske mreže), mikromreža za napajanje potrošača odvojenih od elektroenergetskog sustava te komercijalne i industrijske mikromreže.

Integracijom velikog broja distribuiranih izvora u elektroenergetski sustav, posebice nepredvidljivih obnovljivih izvora energije, koncept mikromreže u znanstvenoj literaturi dobiva na važnosti što se očituje u velikom broju znanstvenih publikacija. U užem pogledu, u posljednje vrijeme stavlja se naglasak na optimalno kratkoročno planiranje pogona mikromreža s obzirom na postavljeni cilj (ekonomski, ekološki, tehnički ili kombinacija više njih) uz što veću otpornost na promjene u budućnosti. Zadatak optimalnog planiranja pogona mikromreže u budućnosti preuzima sustav upravljanja energijom.

Sustav upravljanja energijom može imati različite funkcije cilja koje se žele postići ovisno o veličini izgradnje, geografskim i klimatološkim ograničenjima, električnim ograničenjima, zahtjevima korisnika, vrsti regulatornog okruženja, vrsti potrošača i distribuiranih izvora integriranih u nju što rezultira diverzificiranim rješenjima. Jednu od dvije glavne sastavnice sustava upravljanja energijom predstavlja optimizacijski modul koji na osnovu ulaznih podataka za diskretizirano vremensko razdoblje u budućnosti određuje varijable odluke s obilježjima iznosa, vremena i elementa na koji se primjenjuju. Optimizacijski modul sadržava modele elemenata integriranih u mikromrežu i karakteristike njenog regulatornog okruženja u kojemu se nalazi. Drugu glavnu sastavnicu predstavlja modul za predviđanje ulaznih parametara u optimizacijski problem. Prvi sustavi upravljanja energijom objavljeni u lite-

raturi koriste jednostavne modele elemenata mikromreže, bez prognoza ulaznih parametara i bez mogućnosti prilagodbe na promjene nastale tijekom pogona uzrokovane nepredvidljivom proizvodnjom električne energije iz obnovljivih izvora, nepredvidljivom potrošnjom električne energije mikromreže i nepoznatim cijenama električne energije u budućnosti. Razvojem računalnih sustava visokih performansi i novih optimizacijskih tehnika omogućeno je razvijanje realnijih modela, a različitim optimizacijskim okvirima postiže se otpornost (robusnost) na promjene nastale tijekom pogona koje mogu udaljiti pogon mikromreže od optimalnog. Istraživanje u ovoj disertaciji usmjerava se k razvoju sustava upravljanja energijom mikromreže primjenom optimizacijskog okvira koji povećava otpornost (robusnost) na promjene u budućnosti što je detaljnije definirano područjem i strategijom istraživanja u poglavlju 3.1, temeljeno na pregledu znanstvene literature izvršenom u poglavlju 2.

1.1. Organizacija i struktura doktorske disertacije

Doktorska disertacija podijeljena je u 6 poglavlja.

1. poglavlje daje uvod u koncept mikromreža i njihovu primjenu s naglaskom na izazove prilikom kratkoročnog planiranja pogona istih pomoću sustava upravljanja energijom.

2. poglavlje pruža uvod u strategije rada mikromreža, opisuje najčešće korištene upravljačke sustave mikromreža i osnovna obilježja sustava upravljanja energijom mikromreža. U nastavku je izvršen detaljan pregled literature u području sustava upravljanja energijom promatran sa sljedećih aspekata: vrste mikromreža i elementi koje mikromreže integriraju, tržišno okruženje u koje je mikromreža integrirana, metode za predviđanje ulaznih parametara u optimizacijske probleme, optimizacijski okvir i karakteristike optimizacijskih problema. Na kraju poglavlja izvršen je pregled užeg područja istraživanja odnosno višeslojnih sustava upravljanja energijom mikromreža.

3. poglavlje opisuje područje i strategiju istraživanja disertacije, korišteni optimizacijski okvir i optimizacijske metode primijenjene u optimizacijskim problemima pojedinih slojeva sustava upravljanja energijom mikromreže.

4. poglavlje predstavlja središnji dio disertacije s detaljnim pregledom optimizacijskih problema pojedinih slojeva sustava upravljanja energijom. Opisan je optimizacijski problem višeg sloja sustava upravljanja energijom s matematičkim modelima elemenata mikromreže (nadomjesne mreže na mjestu priključka mikromreže na nadređenu elektroenergetsku mrežu, baterijskog sustava pohrane energije, fotonaponskog sustava, upravljivog generatora i trošila električne energije) koji definiraju ograničenja te funkcije cilja. Opisan je optimizacijski problem nižeg sloja sustava upravljanja energijom s dodatnim ograničenjima te funkcijom cilja. Naposljetku su opisane metode korištene za predviđanje ulaznih parametara u optimizacijske

probleme pojedinih slojeva sustava upravljanja energijom.

5. poglavlje uz 4. poglavlje predstavlja središnji dio disertacije u kojemu se vrednuje unaprijeđeni dvoslojni sustav upravljanja energijom. Na početku poglavlja definiraju se postavke optimizacijskog okvira i optimizacijskih metoda, opisuju se tehničke karakteristike modela elemenata testne mikromreže i postavke tržišnog okruženja u koji je integrirana. Nadalje prikazuje rezultate treniranja umjetnih neuronskih mreža s dugom kratkoročnom memorijom korištene za srednjoročno i kratkoročno prognoziranje ulaznih parametara u optimizacijske probleme (slojeve). U posljednjem dijelu poglavlja prikazani su rezultati primjene unaprijeđenog dvoslojnog sustava upravljanja energijom na kratkoročno planiranje pogona testne mikromreže te analiza rezultata podijeljena na tri dijela. U prvom dijelu promatrao se utjecaj dodatnih (virtualnih) prihoda/troškova funkcije cilja optimizacijskog problema višeg sloja sustava upravljanja energijom, u drugom dijelu vrednovao se utjecaj optimizacijskog okvira dok je u posljednjem dijelu izvršena analiza osjetljivosti funkcije cilja optimizacijskog problema višeg sloja sustava upravljanja energijom na postavke elemenata testne mikromreže.

6. poglavlje donosi zaključak disertacije u kojima su opisane spoznaje nakon provedenog istraživanja.

2. Istraživanja u području sustava upravljanja energijom mikromreža

Mikromreže pružaju mogućnost integracije različitih tehnologija distribuiranih izvora, tehnologija pohrane energije i upravljive potrošnje, a u iznimnim slučajevima omogućava i izoliran (otočni) pogon u odnosu na nadređenu elektroenergetsku mrežu. Upravo je svojstvo upravljivosti mikromreže glavna razlika u odnosu na aktivnu (nereguliranu) distribucijsku mrežu. Krajnjem korisniku mikromreže pružaju veću samodostatnost i pouzdanost opskrbe, kvalitetu električne energije i manje troškove opskrbe električnom energijom, a u nekim slučajevima i ostvarivanje dobiti. S gledišta operatora distribucijskog sustava mikromreže se promatraju kao upravljiva cjelina integrirana u elektroenergetski sustav kao izvor ili potrošač energije ovisno o njenom načinu rada, a u pojedinim slučajevima i kao potencijalni pružatelj pomoćnih usluga sustavu. Zaključno, mikromreže se mogu promatrati kao agregiranje više sudionika u jednu cjelinu koja povezuje i proizvodnu i potrošačku stranu. Sinergijom opskrbe lokalne potrošnje s lokalnom proizvodnjom električne energije iz distribuiranih izvora te ovisno o sudionicima uključenim u proces planiranja i/ili vođenja pogona mogu se klasificirati četiri operacijske strategije operatora/vlasnika mikromreže vidljive i na slici 2.1 [2]:

- Ekološki cilj,
- Tehnički cilj,
- Ekonomski cilj,
- Kombinacija više ciljeva.

Ekološki cilj minimizira emisiju štetnih (stakleničkih) plinova koji su rezultat rada distribuiranih izvora mikromreže pritom zanemarujući tehničke i ekonomske aspekte. Ova strategija se koristi za postizanje ekoloških ciljeva primjenjujući samo fizikalna ograničenja elemenata mikromreže. Tehnički cilj optimira pogon elektroenergetske mreže u smislu minimizacije mrežnih gubitaka, kolebanja napona i opterećenja elemenata mikromreže uz zanemarivanje pogonskih troškova i prihoda. Ovaj cilj uglavnom koriste operatori elektroenergetskog sustava. Ekonomski cilj najčešće je korišten cilj u literaturi čiji je zadatak minimizirati troškove ili maksimizirati dobit bez obzira na ekološki utjecaj i tehničke aspekte pogona elektroenergetskog sustava. Ovu strategiju najčešće koriste operatori ili vlasnici mikromreža kada se

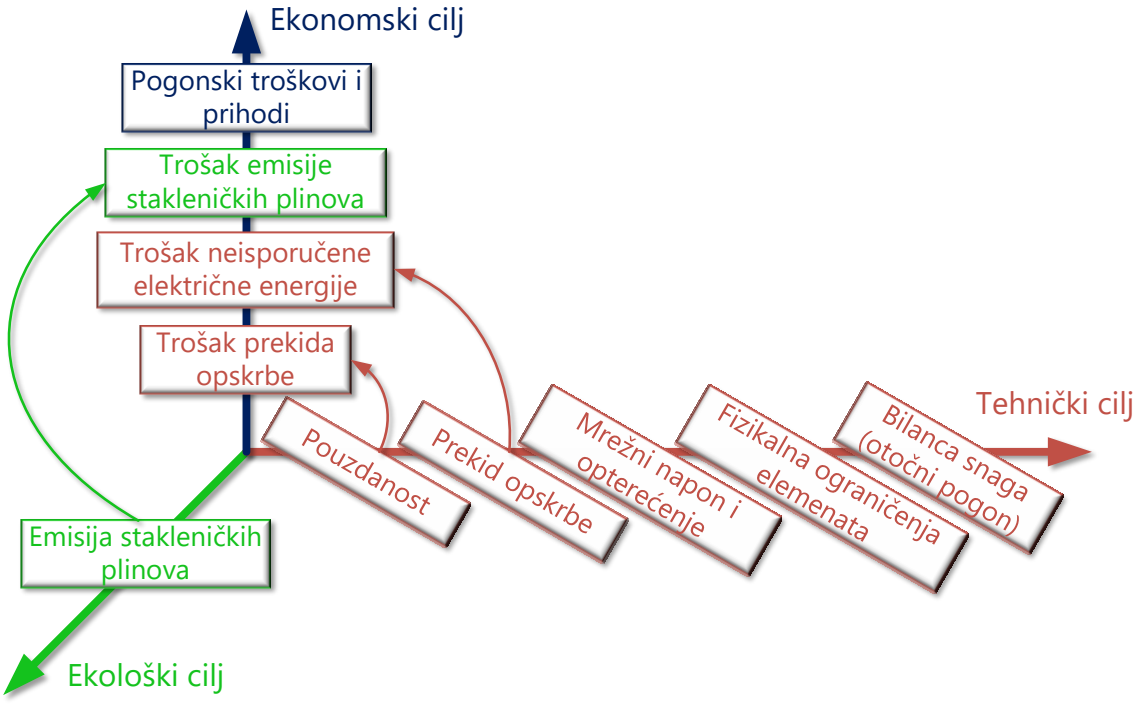

Slika 2.1: *Operacijske strategije mikromreže*

primjenjuju samo fizikalna ograničenja elemenata mikromreže. Moguće je koristiti i strategiju kojom se želi postići dva ili više ciljeva pri čemu se primjenjuju i tehnička i ekološka i ekonomska ograničenja [2].

2.1. Upravljački sustav mikromreže

Kako bi mikromreža bila upravljiva cjelina u odnosu na ostatak elektroenergetskog sustava, mora biti opremljena odgovarajućim sustavom upravljanja. Velik problem u masovnoj eksploataciji mikromreža predstavlja standardizacija rješenja, posebice standardizacije njihovog upravljanja.

Sustavi upravljanja mikromreže u znanstvenoj literaturi klasificirani su u dvije glavne skupine s obzirom na stupanj odgovornosti/slobode pojedinog kontrolera elementa mikromreže koji mogu biti centralizirani ili decentralizirani (distribuirani). S obzirom da ne postoji generalni koncept arhitekture sustava upravljanja mikromreže zbog razlika u veličini izgradnje, tipova i postojećoj infrastrukturi, u znanstvenoj literaturi često se nailazi na koncept sustava upravljanja mikromreže koji ima hijerarhijsku organizaciju s lokalnim i centralnim kontrolerom i komunikacijskim sustavom u tri razine [4]:

- Primarna regulacija realizirana pomoću brzog lokalnog kontrolera zaduženom samo za jedan element mikromreže bilo da se radi o distribuiranom izvoru energije, upravljivom

trošilu ili više agregiranih elemenata,
- Sekundarna regulacija uobičajeno realizirana pomoću centralnog kontrolera zaduženom za koordinaciju i nadzor svih lokalnih kontrolera,
- Tercijarna regulacija koja služi kao posrednik između centralnog kontrolera mikromreže i vanjskih agenata kao što su agregator, operator mreže ili operator tržišta električne energije.

Pomak u pogledu standardizacije sustava upravljanja mikromreže vidljiv je u novom standardu za kontrolere mikromreža IEEE 2030.7-2017 kojim se definira novi upravljački okvir mikromreža u tri razine, koji odgovara ustaljenoj klasifikaciji u znanstvenoj literaturi [5]:

- Niže upravljačke funkcije - regulacija napona, frekvencije, djelatne i jalove snage na razini lokalnih kontrolera pojedinog upravljivog elementa mikromreže,
- Ključne upravljačke funkcije - tranzicija između umreženog i izoliranog pogona i obratno te upravljanje (gospodarenje) energijom,
- Više upravljačke funkcije - komunikacija sa operatorom sustava, operatorom tržišta, agregatorom te integracija u vanjske informacijsko-komunikacijske sustave.

Za razliku od kontrolera primarne regulacije koji je realiziran kao jedna jedinica (niže upravljačke funkcije), kontroleri sekundarne (ključne upravljačke funkcije) i tercijarne regulacije (više upravljačke funkcije) su uobičajeno realizirani u sklopu sustava upravljanja energijom (engl. *Energy management system*). U sustavu centraliziranog upravljanja mikromrežom, sekundarna i tercijarna regulacija zadužene su za optimalno planiranje i vođenje pogona bez obzira na operacijsku strategiju (ekonomski cilj, ekološki cilj, tehnički cilj ili kombinacija). Za razliku od centraliziranog sustava upravljanja, kod decentraliziranog (distribuiranog) sustava upravljačka sposobnost raspodjeljuje se na lokalne kontrolere koji su ovlašteni donositi vlastite odluke [4]. Decentralizirani sustavi upravljanja mikromreže najčešće su realizirani pomoću višeagentnih sustava (engl. *Multi-agent systems*).

2.2. Sustav upravljanja energijom mikromreže

Optimalno planiranje i vođenje pogona mikromreže realizira se pomoću sustava upravljanja energijom. Iako ne postoji jednoznačna definicija, sustav upravljanja energijom prema normi IEC 61970 definira se kao: *"Računalni sustav koji pruža osnovne usluge podrške i set aplikacija potrebne za učinkovit rad proizvodnje električne energije i prijenosnih postrojenja kako bi se osigurala sigurnost opskrbe po minimalnoj cijeni"*. Navedena definicija ograničena je samo na postrojenja prijenosnog sustava i ekonomski cilj dok se sustavom

upravljanja energijom smatra bilo koji računalni sustav odgovoran za implementaciju operacijske strategije koji generira optimalne odluke za svaku upravljivu jedinicu unutar sustava za koji je nadređen, što je primjenjivo i na mikromreže. Sustav upravljanja energijom mikromreže najčešće se koristi za kratkoročno planiranje i vođenje pogona s horizontom planiranja veličine od nekoliko dana iako se u literaturi mogu pronaći i primjeri za dugoročno planiranje pogona (najčešće na godišnjoj razini) kao primjeri u [6–9]. Takve studije uglavnom se koriste za optimalno planiranje konfiguracije i veličine komponenti mikromreže te se neće u nastavku promatrati.

Općenito, sustav upravljanja energijom može se podijeliti na četiri osnovna podsustava [10]:

- Korisničko sučelje (engl. *Human-Machine Interface* - HMI) operatera za nadzor i unošenje ulaznih postavki;
- Računalni sustav za nadzor, prikupljanje podataka i upravljanje (engl. *Supervisory Control and Data Acquisition* - SCADA);
- Modul za predviđanje ulaznih podataka potrebnih za optimizaciju temeljen na trenutnim i povijesnim mjernim podacima;
- Optimizacijski modul odgovoran za optimizaciju pogona generirajući odluke za promatrani horizont planiranja.

Optimizacijski modul i modul za predviđanje ulaznih podataka za optimizacijski modul su glavni dijelovi sustava upravljanja energijom mikromreže te ujedno i tema istraživanja ove doktorske disertacije. U ovoj doktorskoj disertaciji proučava se mikromreža s centraliziranim sustavom upravljanja koja opskrbljuje lokalne potrošače samo jednog energetskog vektora - električna energija. Sekundarna i tercijarna regulacija koja je odgovorna za optimalno planiranje i vođenje pogona uz ograničenja i nesigurnosti tijekom procesa donošenja odluka smatra se implementiranom u centralnom kontroleru mikromreže (engl. *Microgrid central controller*) opremljenim sustavom upravljanja energijom. Centralni kontroler djeluje kao glavni subjekt za komunikaciju između elemenata mikromreže (lokalni kontroleri i senzorska oprema) i vanjskih agenata s mikromrežom omogućujući dvosmjernu komunikaciju. Opća blokovska shema promatranog centraliziranog upravljačkog sustava mikromreže zajedno sa sustavom upravljanja energijom prikazana je na slici 2.2.

Modeliranje sustava upravljanja energijom je multidisciplinaran problem s velikim brojem obilježja zbog diverzificiranosti mogućih izvedbi mikromreža i aspekta pogona. Postoji velik broj znanstvenih radova u časopisima i na konferencijama na ovu temu zbog čega moguće napraviti pregled koji istodobno obuhvaća sva gledišta sustava upravljanja energijom. Slijedom navedenog, u nastavku je prikazan pregled znanstvene literature promatrane

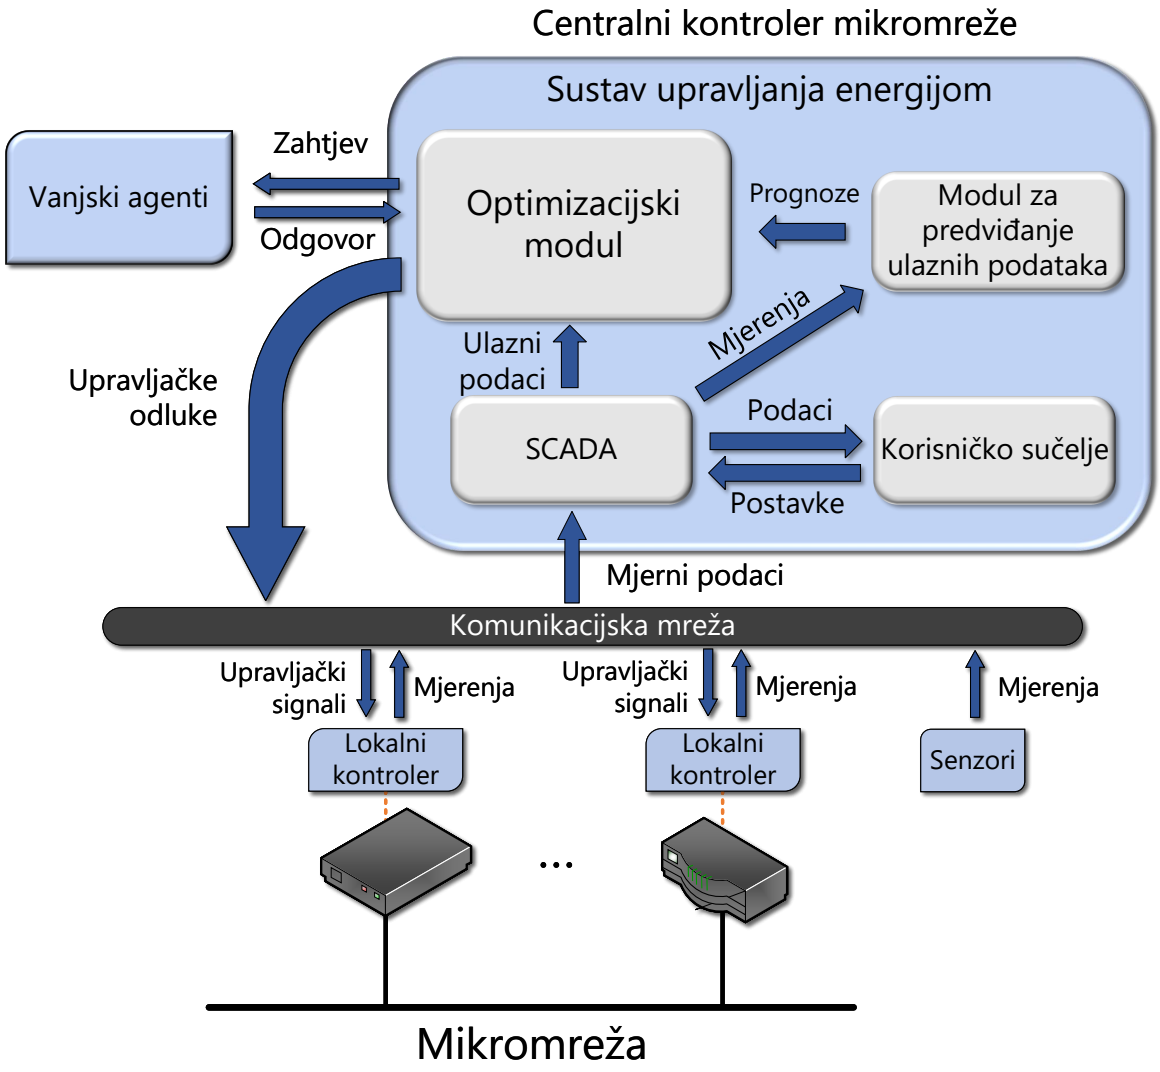

Slika 2.2: *Arhitektura upravljačkog sustava mikromreže*

sa sljedećih aspekata:

- Vrsta mikromreže i elementi koje mikromreža integrira;
- Tržišno okruženje u koje je mikromreža integrirana;
- Metode za predviđanje ulaznih parametara u optimizacijske probleme;
- Optimizacijski okviri i optimizacijski problemi sustava upravljanja energijom mikromreža;
- Višeslojni sustavi upravljanja energijom mikromreža.

2.3. Vrsta i elementi mikromreže

Mikromreže kao koncept mogu se realizirati u velikom broju različitih topologija i elemenata što je njihova prednost. Modeliranje sustava upravljanja energijom mora sadržavati sva obilježja mikromreže koja se modelira kao što su različiti tipovi integriranih distribuiranih

izvora energije, upravljivih trošila i sustava pohrane energije. U obzir se trebaju uzimati i različite topologije mikromreže koje se modeliraju stoga se u literaturi pronalaze primjeri istosmjernih (DC) mikromreža, izmjeničnih (AC) i hibridnih (AC/DC) mikromreža. Iako svaki tip ima svoje prednosti i nedostatke, najčešće korišteni tip mikromreža koji se susreću u literaturi su izmjenične (AC) mikromreže zbog već postojeće infrastrukture.

Jedna od glavnih obilježja i prednosti koncepta mikromreže je mogućnost napajanja lokalnih potrošača u slučaju prekida opskrbe odnosno kvara ili ispada nadređene elektroenergetske mreže čime mikromreža radi u izoliranom (otočnom) pogonu. Unatoč tom osnovnom obilježju mikromreže, u literaturi postoji velik broj sustava upravljanja energijom mikromreže koji ne modeliraju mogućnost rada u izoliranom pogonu [11–17, 17–47].

Optimizacijski modul unutar sustava upravljanja energijom mora sadržavati modele svih elemenata mikromreže zajedno s aspektima pogona mikromreže. U literaturi se pronalaze diverzificirani primjeri mikromreža s različitim upravljivim i neupravljivim elementima kao što su:

- Izvori električne energije:
  - Upravljivi generatori;
  - Obnovljivi izvori energije;
- Trošila električne energije:
  - Neupravljiva (kritična) trošila;
  - Upravljiva trošila;
- Sustavi pohrane električne energije:
  - Elektrokemijski sustavi (sekundarne baterije);
  - Kemijski sustavi;
  - Električni sustavi.

2.3.1. Izvori električne energije

U literaturi se uočava velik broj različitih tehnologija izvora električne energije koje mikromreže integriraju, a ugrubo se mogu podijelit na upravljive i neupravljive izvore. Svojstvo upravljivosti dolazi od mogućnosti regulacije izlazne snage takvih izvora što najčešće ovisi o primarnom energentu (gorivu) koji taj izvor koristi. Upravljivi izvori često služe i kao dodatni (rezervni) sustav napajanja koji je posebno bitan kod izoliranog pogona mikromreže. U literaturi se najčešće modeliraju sljedeće tehnologije upravljivih izvora:

- Generatori s motorom na unutarnje izgaranje (najčešće dizelski ili benzinski) [15, 28, 33, 37, 43, 47–55];

- Mikroturbine [11, 22, 25, 28, 29, 35, 38–42, 44, 47, 49, 50, 52, 55–60];
- Kogeneracijska postrojenja za istovremenu proizvodnju električne i toplinske energije [18, 22, 28, 29, 32, 42, 48, 57, 60–63].

Iako su u pitanju različite tehnologije, matematički modeli ovakvih elemenata uglavnom imaju svojstva optimizacijskog problema angažiranja agregata (engl. *Unit commitment*) i ekonomične raspodjele opterećenja (engl. *Economic dispatching*) sa sljedećim ograničenjima:

- Minimalna/maksimalna izlazna snaga agregata;
- Ograničenje promjene proizvodnje na gore/dolje (engl. *Ramp up/down*);
- Minimalno vrijeme proizvodnje i minimalno vrijeme prestanka proizvodnje;
- Troškovi rada najčešće raspodijeljeni na trošak goriva i trošak pokretanja agregata.

Ograničenja koja se uzimaju u matematičkom modelu ovise o tipu agregata i instaliranoj snazi agregata. Kako se kod mikromreža mogu naći agregati i manjih instaliranih snaga, neka od ograničenja se mogu izostaviti.

Neupravljivi izvori najčešće podrazumijevaju tehnologije na obnovljive izvore energije kod kojih izlazna snaga ovisi o dostupnosti primarnog energenta. U literaturi se najčešće koriste fotonaponski sustavi i vjetrogeneratori kao neupravljivi izvori.

2.3.2. Trošila električne energije

Jedna od osnovnih karakteristika mikromreže je i upravljivost potrošnjom električne energije. Trošila električne energije dolaze u raznim instaliranim snagama i profilima potrošnje. S obzirom na mogućnost upravljanja potrošnjom električne energije u literaturi se najčešće primjenjuje podjela na neupravljiva (kritična) i upravljiva trošila. Neupravljiva trošila u mikromreži predstavljaju skup više trošila (agregirana trošila) koja u svakom trenutku planiranja i vođenja pogona mikromreže zahtijevaju napajanje, a njihovom potrošnjom ne može se upravljati bez obzira radi li se o umreženom ili izoliranom (otočnom) pogonu mikromreže.

Većina sustava upravljanja energijom ne modelira upravljiva trošila, no u literaturi se pronalaze različiti primjeri koji modeliraju skup upravljivih trošila (agregirana upravljiva trošila) ili svako pojedino upravljivo trošilo. Ovisno o načinu modeliranja, kod upravljanja potrošnjom skupa upravljivih trošila postižu se dva efekta: pomicanje potrošnje u drugo vremensko razdoblje (engl. *Load shifting*) i/ili rasterećenje (engl. *Load shedding*). Autori kod ovakvog modeliranja upravljivih trošila smatraju da mikromreža sudjeluje u programima odgovora potražnje (engl. *Demand response programs*) kojima se želi postići isti učinak na profil potrošnje električne energije mikromreže, ali uz određenu financijsku kompenzaciju [12, 15, 28, 32, 33, 37, 49–52, 54–59, 62].

Kod zasebnog modeliranja upravljivog trošila pronalaze se različiti modeli, najčešći je vremenski odgodivo trošilo (engl. *Time-shiftable*) koje svoj ciklus potrošnje može premjestiti u drugo vremensko razdoblje [14,28,34,36,39,40,43,44], a mogu se naći i primjeri statički (uključeno-isključeno) i dinamički (regulacija potrošnje između minimalne i maksimalne vrijednosti) upravljivih trošila koja se koriste samo u slučaju nužde jer ta trošila na kraju ne potroše planiranu energiju svog ciklusa potrošnje [34,36,40,60,64].

2.3.3. Sustavi pohrane električne energije

Za razliku od izvora i trošila električne energije, sustav pohrane električne energije je element s dvosmjernim tokovima snaga što znači da se može ponašati ili kao trošilo ili kao izvor električne energije čime omogućuje fleksibilnost u pogonu, a ima redovitu ulogu uravnoteženja potrošnje i proizvodnje električne energije unutar mikromreže. Osim unutarnje uloge uravnoteženja unutar mikromreže, fleksibilnost se može koristiti i za vanjske agente (izvan mikromreže). U praksi se može naći velik broj različitih tehnologija pohrane električne energije od mehaničkih, elektrokemijskih, kemijskih, električnih do toplinskih sustava. U mikromrežama najčešće se koriste elektrokemijski sustavi pohrane energije u obliku sekundarnih baterija, a u posljednje vrijeme se mogu naći i primjeri kemijskih sustava pohrane energije u obliku vodika kao goriva za gorive ćelije i električnih sustava pohrane u obliku ultrakondenzatora.

Tehnološki najspremniji tipovi elektrokemijskih sustava pohrane električne energije su olovno-kiselinske i litij-ionske baterije. Olovno-kiselinske baterije najkorišteniji su oblik pohrane koje karakterizira niska cijena, lako recikliranje, no nedostatak im je ovisnost kapaciteta o snazi i dubini pražnjenja, gustoća energije i upotreba olova. Litij-ionske baterije su najbrže rastuća tehnologija baterija čija se prodaja udvostručila u razdoblju od 2013. do 2018. godine. Većina kapaciteta se ugrađuje u električna vozila i potrošačke uređaje, a ostatak u stacionarne baterijske spremnike energije. Za razliku od olovno-kiselinskih baterija, litij-ionske baterije karakterizira visoka gustoća energije i visoka učinkovitost, velike snage pražnjenja i veći broj ciklusa unutar životnog vijeka baterije dok su im nedostaci sigurnosne značajke zbog velike ovisnosti performansi o temperaturi [65, 66]. Usprkos visokoj cijeni, litij-ionske baterije se u praksi koriste u istoj mjeri kao i olovno-kiselinske baterije.

Većina sustava upravljanja energijom mikromreže u literaturi ima modeliranu neku od tehnologija sustava pohrane električne energije, a najčešći su upravo elektrokemijski sustavi u obliku olovno-kiselinskih i litij-ionskih sekundardnih baterija [11, 13–17, 19–56, 59–62, 64, 67–69]. Osim baterijskih sustava pohrane energije, u literaturi se nalaze i sustavi upravljanja koje modeliraju gorivu ćeliju koja za gorivo koristi uskladišten vodik [12,28,42,47,57,68].

S aspekta matematičkog modeliranja baterijskih sustava pohrane energije u literaturi se

zapažaju jednostavni modeli s velikim brojem pojednostavljenja i aproksimacija u kojima se zanemaruju bitne značajke koje utječu na pogon. Većina pregledanih sustava upravljanja energijom u literaturi zanemaruje modeliranje dvosmjernog pretvarača energetske elektronike kao jednog od dva osnovna dijela baterijskog sustava pohrane energije [11,13–17,19,20,22,25–27,29,30,32–36,39–47,49–57,59–64,67–69]. Primjeri istraživanja koja modeliraju pretvarač s konstantnom učinkovitošću pretvorbe i konstantnim gubicima pretvorbe energije mogu se naći u [23,24], dok funkcijsku ovisnost učinkovitosti o trenutnom opterećenju pretvarača, kao najtočniju interpretaciju rada pretvarača, modeliraju samo autori u [21,31].

Prilikom modeliranja baterije, kao drugog sastavnog dijela baterijskog sustava pohrane energije, većina istraživanja modelira litij-ionsku tehnologiju sekundarnih baterija uz konstantnu učinkovitost punjenja i pražnjenja te ograničava snagu punjenja i pražnjenja na iznos maksimalne dopuštene vrijednosti definirane tehničkim specifikacijama proizvođača baterije [11,13–17,19–27,29–36,39–47,49–57,59–63,67,68]. Ovo pojednostavljenje može značajno utjecati na točnost, odnosno realnost modela baterijskog sustava pohrane energije jer je otprije poznato da se dopuštena snaga punjenja baterije mijenja tijekom procesa punjenja i ovisi o različitim faktorima, a najviše o trenutnom stanju napunjenosti baterije (engl. *State of Charge*- SOC). U literaturi se pronalazi mali broj primjera s detaljnijim modeliranjem koji ograničavaju snagu punjenja baterije pomoću metode konstantne struje/konstantnog napona (engl. *Constant current/constant voltage* - CC/CV) [64,69].

U baterijama kao elektrokemijskim sustavima pohrane energije se tijekom korištenja odvijaju složeni procesi degradacije na koje utječu razni faktori stresa (engl. *Stress factors*), što posljedično utječe na smanjenje performansi i njihov životni vijek, ponajprije na sposobnost punjenja i pražnjenja te kapacitet. Životni vijek litij-ionskih baterija ovisi o faktorima koji se mogu svrstati u dvije skupine: ovisni o pogonu i neovisni o pogonu [70]. Vanjska temperatura, vlažnost zraka, kalendarska starost i stanje (zdravlja) baterije (engl. *State of health*) spadaju u faktore koji ne ovise o pogonu [71] dok dubina ciklusa pražnjenja baterije (engl. *Cycle depth of discharge*), prekomjerno punjenje i pražnjenje baterije, struje pražnjenja i punjenja (faktor C) te prosječno stanje napunjenosti spadaju u faktore koji ovise o pogonu baterije [72]. Modeliranje faktora koji utječu na degradaciju baterije u literaturi se većinom dijeli na faktore koji uzrokuju cikličko starenje i kalendarsko starenje. Pregledom literature uočava se kako većina sustava upravljanja energijom mikromreža ne uzima u obzir faktore koji utječu na degradaciju baterije što može dovesti do ubrzane degradacije i smanjenja životnog vijeka baterije koje imaju visoke investicijske troškove. Autori koji modeliraju ovaj aspekt, uvrštavaju dodatne (virtualne) troškove u funkciju cilja kojima se sprječava učestalo punjenje i pražnjenje baterije i visoka stanja ispražnjenosti.

Autori u [52] modeliraju fiksni virtualni trošak prilikom pokretanja procesa punjenja ili

pražnjenja i fiksni (operativni) trošak tijekom trajanja punjenja i pražnjena baterije, neovisan o snazi i dubini pražnjenja baterije. Nadalje, autori u [55] modeliraju dvije vrste troška rada baterijskog sustava pohrane energije: trošak tijekom pokretanja ciklusa punjenja ili pražnjenja i fiksni trošak punjenja i pražnjenja ovisan o snazi, ali neovisan o dubini pražnjenja ciklusa. U [15, 37] autori modeliraju trošak ovisan o snazi punjenja/pražnjenja baterije. Autori u [24] također modeliraju dva troška od kojih prvi ovisi o snazi punjenja i pražnjenja baterije, investicijskom trošku i nazivnom broju ciklusa baterije, ali neovisan o dubini pražnjenja svakog ciklusa dok drugi trošak valorizira degradaciju baterije ovisnu o rezultantnoj snazi punjenja i pražnjenja baterije. Istraživanje u [46] modelira degradaciju ovisnu o investicijskim troškovima i o nelinearnoj funkciji gubitka životnog vijeka (broja ciklusa punjenja/pražnjenja) ovisne o dubini pražnjenja ciklusa. Naposlijetku, autori [31] razvili su model, korišten i u istraživanju [25], u kojemu trošak degradacije ovisi o investicijskim troškovima i stanju (zdravlja) baterije koje linearno ovisi o dubini pražnjenja svakog ciklusa.

2.4. Tržišno okruženje mikromreže

Mikromreža može biti integrirana u različita tržišta električne energije, ovisno o primijenjenoj regulativi. Autori sustava upravljanja energijom mikromreža koji ne omogućuju umreženi pogon s nadređenom elektroenergetskom mrežom ne mogu imati modelirane cijene razmjene električne energije, stoga će se promatrati oni sustavi koji omogućuju samo umreženi ili obje vrste pogona u odnosu na nadređenu elektroenergetsku mrežu. Sustavi naplate električne energije, bilo u smjeru preuzimanja energije iz mreže ili predaje u nju, većinom su definirani po jedinci razmijenjene električne energije gdje se taj trošak ili prihod redovito uvrštava u funkciju cilja optimizacijskog problema.

Iako su višetarifni sustavi naplate potrošnje električne energije pasivnih kupaca uobičajena i poznata praksa, autori u literaturi ovakve sustave naplate, posebice kod aktivnih kupaca (krajnji kupci s vlastitom proizvodnjom) u koje se mogu svrstati i mikromreže, promatraju kao jedan od programa odgovora potražnje (engl. *Demand response programs*). Programi odgovora potražnje definiraju se kao mjere koje poduzima operator/agregator sustava kao odgovor uslijed manjka energije za opskrbu kupaca u bliskoj budućnosti. Cilj ovih mjera je utjecati na potrošnju električne energije krajnjih kupaca pomoću različitih tipova programa koji se mogu podijeliti u tri skupine s obzirom na stranu koja potiče promjenu [73]:

- Temeljeni na poticajima (engl. *Incentive-based*) – operator/agregator ovim programima nagrađuje kupce prilikom smanjenja potrošnje električne energije na zahtjev ili zbog davanja dozvole operatoru/agregatoru kako bi upravljao električnim uređajima u

vlasništvu kupca i to u ograničenom stupnju slobode. Kod nekih programa, sudjelovanje kupaca je obvezno dok su ostali dobrovoljni;

- Temeljeni na tarifi (engl. *Rate-based*) – ovi programi se provode pomoću različitih cijena električne energije definiranih od strane opskrbljivača električnom energijom. Pomoću različitih cijena (tarifa) električne energije tijekom različitih vremenskih razdoblja kupce se navodi na promjenu navika u potrošnji električne energije. Cijena električne energije se može definirati za dan unaprijed ili se može mijenjati u stvarnom vremenu na satnoj, dnevnoj ili tjednoj bazi;
- Temeljeni na ponudama smanjenja potrošnje (engl. *Demand reduction bids*) – ovim programima krajnji kupac inicira i šalje ponudu za smanjenje potrošnje operatoru/agregatoru. Ponuda se sastoji od iznosa smanjenja opterećenja (potrošnje) i cijene koju bi operator trebao platiti kupcu za to smanjenje. Ovim programima se uglavnom potiču veliki kupci električne energije kako bi smanjili svoje opterećenje za određenu cijenu koju oni postavljaju ili kako bi dali do znanja koliko su spremni smanjiti potrošnju za određenu cijenu.

Iste programe operator/agregator sustava može primijeniti na mikromrežu ili operator mikromreže na njezine elemente kako bi utjecao na potrošnju električne energije. S aspekta operatora sustava/agregatora mikromreža ima prednost u odnosu na klasičnog kupca s upravljivim trošilima zbog svoje fleksibilnosti u pogonu koju može aktivirati pomoću upravljivih trošila, upravljivih izvora te sustavima pohrane energije.

Većina istraživanja mikromrežu integrira u maloprodajno tržište kao krajnjeg kupca pomoću višetarifnih sustava (engl. *Time of Use*) ili pomoću dinamičkih cijena (engl. *Dynamic pricing*) koje se još nazivaju i sustav naplate po cijenama u stvarnom vremenu (engl. *Real-time pricing*). Ovakav sustav naplate električne energije predstavlja primjer programa odgovora potražnje temeljenih na tarifi. Kod višetarifnih sustava, većina sustava upravljanja energijom mikromreža modeliraju dvotarifne sustave [22, 25, 26, 41, 46, 52, 64, 68, 69], a mogu se naći primjeri s fiksnom cijenom tijekom vremena (jedna tarifa) [31, 62], trotarifnih [29, 45, 55, 62], četverotarifnih [16, 23, 24] i sedmerotarifnih sustava [19, 20]. Cijene su modelirane tako da odražavaju trenutnu potražnju za električnom energijom u elektroenergetskom sustavu. U doba kada je potražnja velika, cijene su visoke i obratno. Primjeri sustava upravljanja energijom mikromreža s dinamičkim cijenama kod kojih se cijena mijenja češće nego kod višetarifnih sustava primjenjuju se u [12, 17, 27, 28, 42, 46, 51, 61, 62, 67].

Kod sustava upravljanja energijom mikromreža koji koriste višetarifne sustave primjenjuje se ista cijena bez obzira na smjer razmjene energije (preuzimanje iz mreže ili predaja u mrežu). Realniji primjeri koji uzimaju različite cijene prilikom preuzimanja odnosno predaje energije u mrežu dostupni su u [15,18,21,31,46,49] što je primjenjivo i na aktivne kupce (kraj-

njih kupaca s vlastitom proizvodnjom) koji imaju integriran sustav za proizvodnju električne energije iz obnovljivog izvora spojen iza brojila. U ovom slučaju se uglavnom primjenjuju regulative s niskim cijenama prilikom predaje energije u mrežu čime se ne stimulira predaja električne energije u mrežu odnosno potiče se vlastita potrošnja energije.

Neki autori sustava upravljanja energijom integriraju mikromrežu na veleprodajno tržište, točnije na tržište dan-unaprijed (engl. *Day-ahead market*) gdje se prije optimiranja pogona za buduće razdoblje preuzimaju cijene električne energije za sljedeći dan [13, 34, 37–39, 41, 43, 47, 53, 54, 56, 57, 59], a mikromreže se smatraju preuzimateljem cijena. Osim tržišta dan-unaprijed, neki sustavi upravljanja energijom koriste i cijene na unutardnevnom tržištu (engl. *Intra-day market*) u slučaju odstupanja planiranog pogona uslijed nesigurnosti koje različiti aspekti kao što su buduća potrošnja ili proizvodnja električne energije unose u optimizacijski problem [32, 40, 44, 48, 58]. Primjena ovog tržišnog okruženja uvelike ovisi o regulativi države koja definira minimalnu instaliranu snagu (veličinu izgradnje mikromreže) potrebnu za sudjelovanje na ovim oblicima tržišta električne energije.

Postoje i sustavi upravljanja energijom koji ne opisuju modelirane cijene razmijenjene energije između mikromreže i nadređene elektroenergetske mreže [11, 14, 30, 50]. Primjer detaljnijeg sustava troška razmijenjene energije dostupan je u [36] gdje je cijena definirana pomoću više tarifnih stavki kao što su fiksna naknada, naknada za razmijenjenu energiju, naknada za angažiranu snagu (engl. *Peak-power pricing*). Naposlijetku, neki autori modeliraju sustave naplate gdje cijena razmijenjene energije ima linearnu ovisnost o trenutnoj snazi razmjene [60], što je rijetko prisutno u praksi.

2.5. Predviđanje ulaznih parametara u optimizacijske probleme

Svaki optimizacijski postupak zahtijeva ulazne podatke odnosno radne varijable o kojima ovisi optimalno rješenje. Jedan set ulaznih varijabli definira jednu radnu točku optimizacijskog problema [74]. Kod optimizacijskih problema za kratkoročno planiranje i/ili vođenje pogona mikromreže optimizacijski postupak provodi se za diskretizirano vremensko razdoblje (horizont planiranja - engl. *Scheduling horizon*) u budućnosti. Svaki diskretni korak (vremenski korak optimizacije - engl. *Optimization timestep*) predstavlja jednu radnu točku optimizacijskog problema. Osim tehničkih karakteristika modela elemenata mikromreže, ulazni podaci kod ovakvih optimizacijskih problema najčešće su profili potrošnje električne energije mikromreže, profili ulaznih/izlaznih veličina za postrojenja na obnovljive izvore energije i cijena električne energije koja ovisi o obliku tržišta u koje je mikromreža integrirana, odnosno niz radnih točaka samog optimizacijskog problema čime se povećava njegova složenost. Točnost predviđanja profila uzlaznih podataka određuje i optimalnost rješenja odnosno što

su prognoze nesigurnije, to je optimalnost rješenja upitnija. U navedenom se ogleda jedna od karakteristika sustava upravljanja energijom, a to je robusnost odnosno otpornost na nesigurnost procjene.

Ako se promatraju karakteristike profila potrošnje i proizvodnje električne iz postrojenja na obnovljive izvore energije, oni ovise o nizu često nepredvidivih parametara. Primjerice, neki od čimbenika koji utječu na potrošnju električne energije su karakteristike trošila čiji se profil potrošnje predviđa (kućanstva, poslovni sektor, industrija), prostorna veličina objekta čija se potrošnja promatra (distribucijsko područje, izvod, kvart, ulica, zgrada, kućanstvo), navike korisnika (obrasci odlaska/dolaska na posao, smjenama, radnom vremenu), meteorološki čimbenici (vanjska temperatura, brzina vjetra, tlak zraka, vlažnost zraka), trenutno vrijeme u danu, tip dana (radni dan, vikend, praznik), trenutni danu u tjednu, mjesecu i godini. Profil proizvodnje postrojenja na obnovljive izvore energije također ovisi i o velikom broju drugih nepredvidivih meteoroloških parametara što dodatno otežava sam proces predviđanja.

Prilikom predviđanja profila potrošnje električne energije i proizvodnje električne energije iz postrojenja na obnovljive izvore energije u literaturi se navode dva pristupa: izravno i neizravno predviđanje. Izravno predviđanje podrazumijeva generiranje profila potrošnje ili proizvodnje snage postrojenja dok neizravno podrazumijeva predviđanje profila ulaznih fizikalnih veličina o kojima ovisi snaga potrošnje ili proizvodnje postrojenja. Ovo također zahtijeva i određeni matematički model koji za rezultat daje snagu potrošnje ili proizvodnje električne energije. Primjer korištenja neizravnog predviđanja se nalazi kod fotonaponskih sustava gdje su snaga sunčevog zračenja i vanjska temperatura ulazni podaci matematičkog modela za numerički proračun izlazne snage fotonaponskog sustava.

U znanstvenoj literaturi postoji velik broj razvijenih metoda za predviđanje profila potrošnje električne energije, a izbor pojedine metode ovisi o više čimbenika kao što su dostupnost povijesnih podataka, duljini horizonta predviđanja (engl. *Forecasting horizon*), razini točnosti meteoroloških podataka i željenoj razini točnosti predviđanja. Ove metode ugrubo se mogu podijeliti na statističke metode i metode računalne inteligencije koje u posljednje vrijeme dominiraju u literaturi [75]. Kod predviđanja ulaznih veličina za postrojenja na obnovljive izvor energije, većina metoda se odnosi na postrojenja koja koriste energiju sunčevog zračenja i energiju vjetra kao primarne energente za pretvorbu u električnu. Kako je ovdje riječ o predviđanju meteoroloških parametara, u literaturi je dostupan veći broj metoda koje se mogu svrstati u kategorije fizikalnih metoda, statističkih metoda, metoda prostorne korelacije, vjerojatnosne metode i metode računalne inteligencije koje su dominantne u novijoj literaturi [76].

U proučenoj literaturi, većina sustava upravljanja energijom mikromreža ne koristi niti

izravnu niti neizravnu metodu (algoritam) za predviđanje profila potrošnje električne energije i profila ulaznih/izlaznih veličina za postrojenja na obnovljive izvore energije, nego se prognoze smatraju savršeno točnima što je neostvarivo u praksi [12,14–20,22,25–30,34,35,37–39,41–45,47,49–54,57,58,60–62,64,67–69]. Sljedeći pristup koji se pronalazi u literaturi je ručno unošenje odstupanja unaprijed poznatim (izmjerenim) profilima ulaznih veličina kako bi se povećala realnost modela [11, 13, 31, 33, 46, 48]. Iako vrlo jednostavan, već ovim pristupom se može ocijeniti robusnost odnosno otpornost sustava upravljanja energijom (optimalnog rješenja) na nesigurnosti u optimizacijskom problemu. Također, u literaturi se pronalaze i primjeri vjerojatnosnog pristupa koji koriste funkcijske razdiobe vjerojatnosti (engl. *Probability density function*) [40, 41, 55, 56, 59]. Funkcije razdiobe vjerojatnosti generiraju se na osnovu povijesnih podataka (mjerenja) pomoću kojih se može generirati proizvoljan broj profila i odrediti vjerojatnost njihovog pojavljivanja.

Tek nekolicina pregledanih sustava upravljanja energijom mikromreža koristi metode za predviđanje ulaznih parametara. Autori u [21] koriste metodu klasteriranja k-sredinama što je statistička metoda koja koristi povijesne podatke o snagama i energiji proizvodnje iz fotonaponskog sustava i potrošnji električne energije za klasifikaciju po određenim tipovima dana i računanje vjerojatnosti njihove pojave koji se dalje koriste za predviđanje ulaznih podataka. Nadalje, autori u [23] koriste dvije različite tehnike za predviđanje za različite horizonte predviđanja. U višem sloju sustava upravljanja energijom koriste adaptivni neuronsko-neizraziti interferentni sustav (engl. *Adaptive neuro-fuzzy interference system*) kao metodu računalne inteligencije za predviđanje potrošnje električne energije, a za predviđanje proizvodnje iz fotonaponskog sustava koriste savršene prognoze na osnovu povijesnih podataka uz ručno generiranje odstupanja. U nižem sloju sustava upravljanja energijom koriste adaptivni autoregresijski algoritam (engl. *Adaptive autoregression algorithm*) kao statističku metodu za predviđanje proizvodnje iz fotonaponskog sustava i potrošnje električne energije. Slična primjena vidljiva je u [24] gdje isti autori primjenjuju isti adaptivni autoregresijski algoritam za predviđanje proizvodnje iz fotonaponskog sustava i potrošnje električne energije. Autori u [32] koriste metodu potpornih vektora najmanjih kvadrata (engl. *Least-square support vector machine*) kao metodu računalne inteligencije za predviđanje proizvodnje fotonaponskog sustava dok za predviđanje potrošnje ne navode niti jednu metodu. Primjer korištenja još jedne statističke metode je dostupan u [36] u kojemu autori koriste višestruku linearnu regresiju s egzogenim varijablama (engl. *Multiple linear regressions with exogenous explanatory variables*) s modelom pokretnih prosjeka (engl. *Moving Average* - MA). Autori u [40] koriste statističku metodu autoregresivnog integralnog modela pokretnih prosjeka (engl. *Autoregressive Integrated Moving Average Model* - ARIMA) za predviđanje proizvodnje iz fotonaponskog sustava, vjetrogeneratora i potrošnje električne energije.

2.6. Optimizacijski okvir i optimizacijski problemi sustava upravljanja energijom

Pregledom literature utvrđeno je postojanje velikog broja različitih tretiranja gledišta prilikom modeliranja. Neka gledišta se naglašavaju dok se ostala zanemaruju ili se uzimaju u obzir u manjoj mjeri kroz aproksimacije. Upravo je složenost modeliranja sustava upravljanja energijom razlog diverzificiranosti rješenja koja se pronalaze u literaturi. Kako bi se napravio iscrpan pregled područja optimizacijskih okvira i svojstava optimizacijskih problema koji se koriste u sustavima upravljanja energijom mikromreža, oni će se promatrati s nekoliko različitih gledišta:

- Optimizacijski okvir;
- Optimizacijska metoda;
- Funkcije cilja i ograničenja.

2.6.1. Optimizacijski okviri

Sustavi upravljanja energijom mikromreža najčešće se koriste za kratkoročno planiranje i/ili vođenje pogona s horizontom planiranja od nekoliko dana. Zadatak ovakvih problema je optimirati pogon za diskretizirano vremensko razdoblje (horizont planiranja) u budućnosti. Horizont planiranja sastoji se od više diskretnih koraka (vremenski korak optimizacije) gdje svaki korak predstavlja jednu radnu točku optimizacijskog problema i u tom koraku se smatra da su veličine konstantne odnosno nepromjenjive. Razvojem tehnologija za proizvodnju električne energije iz obnovljivih izvora posebice fotonaponskih tehnologija i tehnologija koje koriste energiju vjetra, povećala se razina njihove integracije, a samim time i nepredvidljivost proizvodnje što unosi dodatne poteškoće prilikom optimiranja pogona. Zbog toga se u posljednje vrijeme u literaturi stavlja naglasak na modeliranje sustava upravljanja energijom otpornih na promjene odnosno nesigurnosti koje u optimizacijski problem unose:

- Potrošnja električne energije mikromreže u budućnosti;
- Proizvodnja električne energije iz postrojenja na obnovljive izvore u budućnosti;
- Cijene električne energije u budućnosti.

Ukoliko dođe do promjena u inicijalnim prognozama ulaznih parametara nakon izvršenog optimizacijskog postupka, optimalnost rješenja postaje upitna zbog promijenjenih pretpostavki o trendovima kretanja veličina koje predstavljaju ulazne podatke. Takva situacija stvara prvu podjelu optimizacijskih okvira na *online* i *offline* optimizaciju. Većina sustava upravljanja energijom koristi *offline* pristup optimizaciji u kojemu se proces optimizacije

izvršava samo jedanput i to prije početka promatranog horizonta planiranja [12, 15, 17, 25–29, 31, 34, 35, 39–43, 50, 51, 53, 54, 56, 59–63, 67, 68]. Za razliku od *offline* optimizacije, *online* optimizacija podrazumijeva izvršavanje procesa optimizacije svaki vremenski korak ili kad god su dostupne nove prognoze ulaznih parametara. Ovime se postiže veća otpornost (adaptivnost) sustava upravljanja energijom na promjene. Jedna od najkorištenijih strategija u literaturi koja implementira *online* optimizaciju je strategija pomičnog (klizajućeg) horizonta (engl. *Rolling horizon strategy*), tehnika koja se često koristi u modelskom prediktivnom upravljanju (engl. *Model predictive control*) za minimiziranje utjecaja nesigurnih parametara [11, 13, 14, 16, 18–24, 30, 32, 33, 36, 44–49, 52, 55, 57, 58, 64, 69]. Modelsko prediktivno upravljanje koristi se za diskretno upravljanje koje podrazumijeva da se iznosi upravljačkih veličina ne mijenjaju tijekom jednog vremenskog koraka.

Iako se u literaturi ova dva obilježja često ne proučavaju i zanemaruje se njihov utjecaj, kod *online* optimizacijskih okvira duljina horizonta planiranja i duljina vremenskog koraka igraju veliku ulogu u performansama samog sustava upravljanja energijom. Ako se primjenjuje *online* optimizacijski okvir, treba imati na umu da optimizacijski postupak mora završiti prije sljedećeg vremenskog koraka ili prije osvježavanja prognoza ulaznih parametara (sljedeći optimizacijski korak) kako bi se generirane odluke proslijedile lokalnim kontrolerima elemenata mikromreže. Duljina horizonta planiranja i duljina svakog vremenskog koraka optimizacije predstavljaju dvije oprečne karakteristike. Duljim horizontom planiranja postiže se bolja otpornost na buduće promjene koje će nastati uslijed nesigurnih parametara, ali u isto vrijeme se povećava i računalna složenost optimizacijskog problema čime se povećava vrijeme izvršavanja optimizacijskog postupka, i suprotno. Jedan od pristupa za postizanje zadovoljavajuće računalne složenosti koje autori koriste u literaturi je uvođenje aproksimacija u optimizacijski problem čime se smanjuje realnost modela. Nadalje, duljim vremenskim korakom optimizacije smanjuje se računalna složenost optimizacijskog problema, a u isto vrijeme se smanjuje otpornost na promjene jer se kod ovakvih optimizacijskih problema smatra da su veličine unutar jednog vremenskog koraka nepromjenjive. Nemogućnost sagledavanja promjena koje se događaju unutar jednog vremenskog koraka može udaljiti pogon mikromreže od optimalnog. Ovaj utjecaj se posebice susreće prilikom integracije postrojenja za proizvodnju električne energije iz obnovljivih izvora (ponajprije fotonaponski sustavi i vjetrogeneratori) čija je proizvodnja nepredvidljiva i stohastička.

U literaturi se većinom pronalaze sustavi upravljanja energijom mikromreža koji imaju duljinu horizonta planiranja od 24 sata (jedan dan) [13–15, 19–26, 28–31, 33–44, 46–58, 60–64, 68, 69], a rjeđe se nalaze primjeri sa 6-satnim [32, 46], 12-satnim [45, 46, 59], 20-satnim [18], 48-satnim [11, 46, 67], 72-satnim [46], 96-satnim [27, 46] i 168-satnim (jedan tjedan) [12, 16, 17] horizontom planiranja. Razlog velikog broja sustava upravljanja energijom s 24-

satnim horizontom planiranja nalazi se u obrascima ulaznih profila u optimizacijske probleme (potrošnja i proizvodnja električne energije) koji se ciklički ponavljaju u određenoj mjeri svakih 24 sata te njegovo povećanje ne utječe značajno na poboljšanje performansi sustava upravljanja energijom, što je potvrđeno i u [46].

Ukoliko se analiziraju vremenski koraci optimizacije sustava upravljanja energijom, u literaturi se najčešće koriste satne vrijednosti [11, 12, 15, 18–20, 25–29, 35–37, 39–44, 46, 47, 49, 50, 53, 54, 56–59, 61, 62, 64, 67–69] koje su povezane sa veleprodajnim tržištima električne energije u kojima se većinom koriste satne vrijednosti za davanje ponuda za kupnju ili prodaju. S aspekta mikromreže, koje za razliku od elektroenergetskog sustava određenog područja (države) imaju višestruko manju instaliranu snagu, vremenski korak od jednog sata može rezultirati nemogućnošću sagledavanja promjena koje se događaju unutar tog vremenskog koraka. Stoga se u literaturi mogu naći primjeri s 30-minutnim [13, 30, 48, 52], 15-minutnim [14, 16, 17, 21–24, 32, 34, 38, 45, 51, 60], 10-minutnim [31, 39], 5-minutnim [33, 47, 52, 55, 63] i 1-minutnim [23, 24, 39, 49] vremenskim korakom čime se povećava otpornost na promjene.

Kompromisno rješenje za ove dvije oprečne karakteristike optimizacijskog problema je raščlanjivanje problema kratkoročnog planiranja pogona na više optimizacijskih problema (najčešće dva) s različitim horizontom planiranja i vremenskim koracima optimizacije. Ovakvi sustavi upravljanja energijom nazivaju se višeslojni sustavi upravljanja energijom gdje svaki optimizacijski problem predstavlja jedan sloj. Slojevi su međusobno povezani odnosno generirane odluke nakon optimizacijskog postupka iz jednog sloja utječu na odluke ostalih slojeva i obrnuto. Povezivanjem više optimizacijskih problema s različitim karakteristikama postiže se veća otpornost na promjene. Naprimjer, prvi sloj sustava upravljanja energijom može imati dulji horizont planiranja s duljim korakom optimizacije i jednostavnim modelima elemenata čime se ubrzava vrijeme optimizacijskog postupka i povećava otpornost na promjene u budućnosti, dok je drugi sloj modeliran s puno kraćim horizontom planiranja i kraćim vremenskim korakom optimizacije od prvog sloja što omogućuje bolju otpornost na promjene nastale u bliskoj budućnosti i realnije modeliranje elemenata mikromreže s manje aproksimacija. Pregled dvoslojnih sustava upravljanja energijom obrađen je u poglavlju 2.7

2.6.2. Optimizacijska metoda

U literaturi se pronalazi velik broj različitih metoda primijenjenih za modeliranje i rješavanje optimizacijskih problema. Odabir metode ponajprije ovisi o načinu modeliranja optimizacijskog problema i korištenog pristupa. Pregledom literature uočavaju se dvije osnovne skupine optimizacijskih pristupa korištenih prilikom dizajniranja optimizacijskih problema, deterministički i stohastički. Kod determinističkih pristupa smatra se da su svi ulazni parametri u optimizacijski problem poznati s određenom sigurnošću [12–28, 30–39, 42,

43, 46–49, 51, 52, 54, 55, 58, 60–64, 68, 69] dok se kod stohastičkih pristupa uvrštava svojstvo slučajnosti i u literaturi je najčešće korišten pristup stohastičkog programiranja za modeliranje ovakvih optimizacijskih problema [11, 40, 41, 45, 53, 54, 56, 57, 59]. Odabir pristupa ponajprije ovisi o korištenim metodama za predviđanje ulaznih parametara u optimizacijske probleme. Stohastički pristupi koriste funkcije razdiobe vjerojatnosti koje na osnovu povijesnih podataka generiraju proizvoljan broj mogućih scenarija koji se onda koriste u optimizacijskim problemima. Osim stohastičkog programiranja, mogu se naći primjeri robusnog programiranja [29, 41, 44, 50] koji također unose svojstvo slučajnosti u optimizacijski problem pomoću funkcija razdiobe vjerojatnosti određenih ulaznih parametara, ali imaju određena obilježja deterministčkih optimizacijskih pristupa.

Ako se promatraju optimizacijske metode, u literaturi se pojavljuje širok spektar korištenih metoda koje se ugrubo mogu svrstati u metode matematičkog programiranja, metode temeljene na inteligentnoj pretrazi prostora rješenja (metode približenja globalnom optimumu), metode temeljene na pravilima neizražene logike (engl. *Fuzzy logic*) i hibridne metode.

U literaturi su najzastupljenije metode matematičkog programiranja. Matematičko programiranje pripada većem skupu metoda matematičke optimizacije, a definira se kao numeričko rješavanje problema minimizacije ili maksimizacije funkcije [74]. Da bi metode matematičkog programiranja mogle primijeniti, funkcija cilja i ograničenja moraju imati određeni oblik.

To ujedno zahtijeva prilagodbu optimizacijskog problema kratkoročnog planiranja pogona mikromreže korištenoj metodi i najčešće unosi određene aproksimacije stvarnog procesa da bi se mogao uvrstiti u optimizacijski problem. Prilikom modeliranja ovakvih optimizacijskih problema u literaturi se najčešće koristi metoda linearnog programiranja (engl. *Linear programming*) [12, 22, 68] i mješovitog cjelobrojnog linearnog programiranja (engl. *Mixed-Integer Linear Programming*) [14, 18, 21, 23, 24, 29, 32, 34, 36–41, 43–45, 47, 48, 52, 55, 57, 59, 63, 64, 68, 69]. Kod mješovitog cjelobrojnog linearnog programiranja funkcija cilja i ograničenja su linearne, a neke varijable poprimaju cjelobrojnu vrijednost. Ako se promatraju optimizacijski problemi prema složenosti njihovog rješavanja, u literaturi se mogu naći primjeri optimizacijskih problema čija funkcija ima kvadratnu ovisnost o varijablama, a ograničenja su linearna, odnosno primjenjuje se kvadratno programiranje (engl. *Quadratic programming*) [13, 19, 20, 30, 46, 52], a u slučaju uvrštavanja i cjelobrojnih varijabli koristi se mješovito cjelobrojno kvadratno programiranje (engl. *Mixed-integer quadratic programming*) [11, 62]. Nadalje, ako je optimizacijski problem modeliran tako da je funkcija cilja ili neko od ograničenja u nelinearnoj ovisnosti, optimizacijski problem postaje nelinearan što zahtijeva korištenje metode nelinearnog programiranja (engl. *Nonlinear programming*) [22, 26, 53, 55] i mješovitog cjelobrojnog nelinearnog programiranja (engl. *Mixed-*

integer nonlinear programming) [28, 35, 44, 46, 54], ako su prisutne i cjelobrojne varijable. Osim najčešće korištenih metoda navedenih iznad, u literaturi se pronalaze primjeri koji koriste dinamičko programiranje (engl. *Dynamic programming*) [31], sekvencijalno linearno programiranje (engl. *Sequential linear programming*) [58], sekvencijalno kvadratno programiranje (engl. *Sequential quadratic programming*) [42], semidefinitno programiranje (engl. *Semidefinite programming*) [33, 35], konveksno mješovito cjelobrojno programiranje konusa drugog reda (engl. *Convex mixed-integer second order cone programming*) [50], a prisutne su i hibridne metode korištenja dinamičkog programiranja i linearnog programiranja [25] te transformacija mješovito cjelobrojnog nelinearnog programiranja u semidefinitno programiranje [35].

Osim metoda matematičkog programiranja, u literaturi se mogu naći primjeri korištenja metoda temeljenih na inteligentnoj pretrazi prostora rješenja često nazivane i metaheurističke metode (engl. *Metaheuristics*) - metode približenja globalnom optimumu. Ove metode su često nadahnute pojavama ili ponašanjima u društvu i životinjskom svijetu te ne zahtijevaju poznavanje karaktera funkcije cilja, nego samo numeričku vrijednost funkcije što omogućuje modeliranje realnijih optimizacijskih problema uz manje aproksimacija. Najčešće upotrijebljena metoda u literaturi prilikom modeliranja sustava upravljanja energijom mikromreže je optimizacija rojem čestica (engl. *Particle swarm optimization*) [27, 49, 51, 68]. Osnovna ideja ove metode je simulirati ponašanje ptica ili riba u jatu odnosno njihovo društveno ponašanje. Jato predstavlja populaciju dok svaka individualna ptica ili riba predstavlja česticu u prostoru rješenja te se pri kretanju čestice kreću prema trenutno najboljoj uz zadržavanja određenog stupnja individualnog ponašanja [74]. Osim optimizacije rojem čestica, u literaturi se pronalaze slučajevi korištenja optimiranja pomoću algoritma društvenog ponašanja grbavih kitova (engl. *Whale optimization algorithm*) [15] te genetskog algoritma (engl. *Genetic algorithm*) [60] koji pripada skupini evolucijskih algoritama pomoću kojih se oponaša proces prirodne selekcije. Također se nalaze primjeri koji koriste algoritam najkorisnijeg igrača (engl. *Most valuable player algorithm*) nadahnut timskim sportovima [61], a prisutni su i hibridni algoritmi koji kombiniraju genetski algoritam s optimizacijom rojem čestica [56] te genetski algoritam s neizrazitom logikom [16, 17]. Osim optimizacijskih algoritama, u literaturi se pojavljuju i sustavi upravljanja energijom temeljenim na pravilima (engl. *Rule-based*) gdje se ne koristi optimizacijski postupak, nego se odluke donose na osnovu striktno definiranih uvjeta [23, 67].

2.6.3. Funkcije cilja i ograničenja

U literaturi se pronalaze različite vrste i brojnost funkcija cilja optimizacijskog problema. S obzirom na brojnost, najveći broj sustava upravljanja energijom mikromreža u literaturi

optimira jednu funkciju cilja [11–27, 29–48, 50–55, 57–59, 61–64, 67–69] dok se rjeđe mogu naći primjeri s više funkcija cilja (višeciljna optimizacija) [28, 49, 56, 60].

U optimizacijskim problemima se mogu naći tri vrste ciljeva odnosno strategija rada mikromreže, ekonomski, ekološki i tehnički cilj, a najčešće se želi postići ekonomski [12, 14–18, 18–21, 23–27, 29–32, 34, 36–45, 48, 51, 52, 54, 55, 57–59, 61–64, 67–69]. Kod ekonomskih ciljeva najčešće se koristi funkcija s više članova gdje svaki član predstavlja prihod ili trošak. Najčešća ekonomska funkcija cilja u literaturi je minimizacija troškova rada mikromreže gdje se pribrajaju troškovi preuzimanja i prihodi od predaje električne energije iz/u nadređenu elektroenergetsku mrežu, troškovi rada upravljivih generatora, trošak degradacije spremnika energije, trošak upravljanja potrošnjom ili prihod od aktivacije nekog od programa odgovora potražnje, trošak neisporučene energije, troškovi gubitaka električne energije u mreži te prihodi od pružanja pomoćnih usluga u sustavu. Nadalje, pronalazi se i čisto tehnički cilj minimizacije varijabilnosti razmijenjene snage mikromreže i nadređene elektroenergetske mreže [11]. Niti jedan sustav upravljanja energijom iz pregledane literature ne optimira čisto ekološki cilj, nego se pronalaze kombinacije s ekonomskim ciljem. Autori često kombiniraju više funkcija cilja u jednu funkciju cilja zbrajanjem odnosno oduzimanjem pojedinih članova čime ona postaje zbirna funkcija cilja. Ovakva funkcija cilja ne predstavlja višeciljnu optimizaciju, iako je u pitanju optimiranje različitih ciljeva (strategija). Kombinacija tehničkog i ekonomskog cilja pronalazi se u [13, 28, 33, 35, 46, 47, 50, 53] gdje se tehnički ciljevi najčešće kombiniraju s minimizacijom troškova rada mikromreže. Kombinacija ekološke i ekonomske funkcije cilja koristi se u [22, 56, 60] gdje se kod ekoloških ciljeva najčešće minimiziraju emisije stakleničkog plina ugljikovog dioksida (CO_2), a kod ekonomskog cilja minimiziraju troškovi rada mikromreže. Kombinacija sva tri cilja, ekonomskog, tehničkog i ekološkog, u jednoj zbirnoj funkciji cilja se može naći u [49] gdje se minimiziraju troškovi rada, emisije stakleničkog plina ugljikovog dioksida i želi se postići neki tehnički aspekt pogona kao što je povećana pouzdanost napajanja u izoliranom pogonu ili minimiziranje neisporučene energije trošilima.

Ograničenja optimizacijskih problema ovise o modeliranim elementima mikromreže i pogonskim aspektima, a oblik ograničenja ovisi ponajprije korištenoj optimizacijskoj metodi. Naprimjer, ako se koristi linearno programiranje, ograničenja mogu biti polinomi prvog stupnja u obliku jednakosti ili nejednakosti. Ako se promatraju elementi mikromreža, najčešća ograničenja predstavljaju fizikalna ograničenja elemenata. Osim fizikalnih ograničenja, kod metoda matematičkog programiranja potrebno je definirati i bilancu snage u mikromreži kao ograničenje.

Ako se proučavaju sustavi upravljanja energijom mikromreža s obzirom na način modeliranja elektroenergetske mreže, najčešći oblik koji se nalazi u literaturi je modeliranje

mikromreže kao jednosabirnički sustav (engl. *Single bus bar microgrid*) [11,14–21,23,24,27–32,34,36–43,45–49,55–57,59–64,67–69]. Kod ovakvog modeliranja elektroenergetske mreže promatraju se samo tokovi radne snage, električka ograničenja mikromreže se zanemaruju što znači da su svi elementi spojeni na jednu, glavnu sabirnicu odakle i dolazi sam naziv. Ako sustav upravljanja energijom mikromreže uzima u obzir jednadžbe tokova snaga, omogućuje se primjena dodatnih električkih ograničenja optimizacijskog problema kao što su minimalni i maksimalni iznosi napona na sabirnicama i strujna opterećenja grana kao što su vodovi, kabeli i transformatori te bilanca tokova jalovih snaga [12,13,22,25,26,33,35,44,47,50–55,58].

2.7. Višeslojni sustavi upravljanja energijom mikromreža

U ovom poglavlju prikazan je pregled užeg područja istraživanja doktorske disertacije u pogledu korištenog optimizacijskog okvira sustava upravljanja energijom tj. višeslojnih sustava upravljanja energijom mikromreža. U literaturi se uglavnom susreću dvoslojni sustavi upravljanja energijom gdje prvi sloj ima ulogu planiranja pogona za određen horizont planiranja u budućnosti, a drugi minimizaciju korektivnih mjera uzrokovanih promjenama u prognozama ulaznih parametara. Koriste se i sustavi s tri sloja [77]) gdje treći sloj predstavlja fizički (eksperimentalni) sloj za vođenje pogona mikromreže u stvarnom vremenu, no takav sustav neće biti predmet istraživanja ove doktorske disertacije.

Autori u [69] predstavili su dvoslojni adaptivni sustav upravljanja energijom mikromreže gdje se u višem sloju koristi mješovito cjelobrojni linearni program za kratkoročno planiranje pogona u budućnosti temeljen na strategiji pomičnog horizonta (*online* optimizacija) s ciljem minimizacije troškova rada, a u niži je realiziran kao fizički (eksperimentalni) sloj s ciljem minimizacije korektivnih mjera nastalih uslijed promjena na temelju pravila odnosno bez optimizacijskog postupka. Predstavljen sustav koristi u višem sloju vremenski korak od 1 sata i horizont planiranja od 24 sata, ne integrira dodatni (rezervni) izvor napajanja u obliku upravljivog generatora, ne integrira upravljiva trošila niti integrira električka ograničenja mikromreže (jednadžbe tokova snaga), koristi jednostavni matematički model baterijskog sustava pohrane energije i ne koristi niti jednu metodu za predviđanje profila ulaznih parametara (smatra se da su profili unaprijed poznati).

Autori u [49] predstavili su dvoslojni sustav upravljanja energijom mikromreže koji u višem sloju planira kratkoročni pogon mikromreže pomoću nelinearnog *offline* optimizacijskog problema riješenog modificiranom optimizacijom roja čestica za sljedeća 24 sata s vremenskim korakom od 1 sata s ciljem minimizacije troškova rada, emisije stakleničkih plinova i neisporučene energije potrošačima, a rezultat su generirani scenariji pogona od kojih operator mikromreže odabire željeni. Nakon odabira scenarija, niži sloj realiziran kao neli-

narni optimizacijski problem temeljen na strategiji pomičnog horizonta (*online* optimizacija) s vremenskim korakom od 1 minute optimira pogon na osnovu osvježenih prognoza kako bi mikromreža pratila željeni scenarij. Sustav ne modelira električka ograničenja mikromreže (jednadžbe tokova snaga), ne koristi niti jednu metodu za predviđanje profila ulaznih parametara (smatra se da su profili unaprijed poznati) i koristi jednostavni matematički model baterijskog sustava pohrane energije.

Dvoslojni sustav upravljanja energijom mikromreže gdje se u višem sloju koristi mješovito cjelobrojni linearni *offline* optimizacijski problem za optimiranje pogona za sljedeća 24 sata na osnovu 15 minutnog vremenskog koraka s ciljem minimizacije troškova rada predstavili su autori u [23]. U višem sloju koriste adaptivni neuronsko-neizraziti interferentni sustav za predviđanje potrošnje, a proizvodnja električne energije iz fotonaponskog sustava je generirana ručno. Niži sloj je modeliran kao kontroler temeljen na pravilima bez optimizacijskog postupka s ciljem planiranja pogona baterijskog sustava pohrane energije tako da mikromreža prati profil razmjene energije s nadređenom elektroenergetskom mrežom definiran u višem sloju. Niži sloj je temeljen na strategiji pomičnog horizonta (*online* optimizacija) s vremenskim korakom od 1 minute, a za predviđanje proizvodnje iz fotonaponskog sustava i potrošnje električne energije koristi adaptivni autoregresijski algoritam. Predstavljen sustav upravljanja energijom ne omogućuje izoliran pogon mikromreže, ne implementira električka ograničenja mikromreže (jednadžbe tokova snaga), koristi jednostavni matematički model sustava pohrane električne energije, ne integrira upravljivi generator kao dodatni (rezervni) izvor napajanja, niti upravljiva trošila.

Dvoslojni sustav upravljanja energijom mikromreže predstavljen u [23] unaprijeđen je od strane istih autora u [24]. Ova dva sustava razlikuju se po unaprijeđenom nižem sloju gdje se, osim kontrolera temeljenog na pravilima, koristi i kvadratni optimizacijski problem za planiranje pogona rada baterijskog sustava pohrane energije. U višem sloju se koristi metoda konveksne optimizacije u čijoj su funkciji cilja uvršteni i troškovi rada baterijskog sustava pohrane energije te sustav dodatno integrira vjetrogenerator kao neupravljiv izvor. Ostale značajke predstavljenog sustava upravljanja energijom iste su kao u [23].

Dvoslojni sustav upravljanja energijom predstavljen u [52] koristi u višem sloju mješovito cjelobrojni linearni *online* optimizacijski problem s ciljem minimizacije troškova rada mikromreže za sljedeća 24 sata s vremenskim korakom od 30 minuta, a u nižem sloju kvadratni *online* optimizacijski problem s ciljem minimizacije korektivnih mjera nastalih uslijed promjena za sljedeći vremenski korak koji iznosi 5 minuta. Niži sloj integrira pojednostavljene jednadžbe tokova snaga za ostvarenje električkih ograničenja mikromreže, ne koristi metode za predviđanje ulaznih parametara (smatraju se unaprijed poznatim) i koristi jednostavni matematički model baterijskog sustava pohrane energije.

Autori u [54] predstavili su dvoslojni sustav upravljanja energijom koji u višem sloju koristi stohastičko programiranje za rješavanje mješovito cjelobrojnog nelinearnog *offline* optimizacijskog problema s ciljem minimizacije troškova rada mikromreže za sljedeća 24 sata s vremenskim korakom od 1 sata. Viši sloj također integrira električka ograničenja mikromreže (jednadžbe tokova snaga). U nižem sloju se koristi deterministički pristup rješavanja mješovitog cjelobrojnog nelinearnog *offline* optimizacijskog problema s ciljem minimizacije troškova rada i vremenskim korakom od 1 sata. Sustav ne omogućuje izoliran pogon mikromreže, ne koristi metode za predviđanje ulaznih parametara (smatraju se unaprijed poznatim) i koristi jednostavni matematički model baterijskog sustava pohrane energije.

Dvoslojni sustav upravljanja energijom predstavljen u [55] u višem sloju koristi mješovito cjelobrojni linearni *online* optimizacijski problem s ciljem minimizacije troškova rada mikromreže za sljedeća 24 sata s vremenskim korakom od 5 minuta. Niži sloj koristi nelinearni *offline* optimizacijski problem s istim vremenskim korakom kao i viši sloj te integrira električka ograničenja mikromreže (jednadžbe tokova snaga) s ciljem minimizacije korektivnih mjera nastalih uslijed promjene prognoza ulaznih parametara. Niži sloj optimira pogon samo za prvi sljedeći vremenski korak (horizont planiranja) na osnovu osvježenih prognoza dok se viši sloj poziva samo u slučaju neizvodivog rješenja. Predstavljeni sustav koristi isti vremenski korak u oba sloja što ne doprinosi poboljšanju otpornosti na promjene, koristi jednostavni matematički model baterijskog sustava pohrane energije te ne koristi egzaktnu metodu za predviđanje ulaznih parametara u optimizacijske probleme, nego se ručno unose odstupanja unaprijed poznatim (izmjerenim) profilima ulaznih veličina.

U [44] autori su predstavili dvoslojni sustav upravljanja energijom mikromreže koji u višem sloju koristi mješovito cjelobrojni linearni *offline* optimizacijski problem s ciljem minimizacije troškova rada mikromreže i davanja ponude na tržištu električne energije danunaprijed za sljedeća 24 sata s vremenskim korakom od 1 sata. U nižem sloju koristi se robusna optimizacija mješovito cjelobrojnog nelinarnog *offline* optimizacijskog problema s ciljem minimizacije korektivnih mjera nastalih uslijed promjena prognoza ulaznih parametara sudjelovanjem na promtnom (spot) tržištu električne energije. Niži sloj također optimira pogon za sljedećih 24 sata uz vremenski korak od 1 sata te integrira električka ograničenja mikromreže pojednostavljenjem nelinearnih jednadžbi tokova snaga kako bi se mogle uvrstiti u linearni optimizacijski problem. Sustav ne omogućuje izoliran pogon mikromreže, implementira jednostavni matematički model baterijskog sustava pohrane energije i ne koristi metode za predviđanje ulaznih parametara (smatraju se unaprijed poznatim).

Dvoslojni sustav upravljanja energijom predstavljen u [46] koristi u višem sloju mješovito cjelobrojni nelinearni *online* optimizacijski problem s ciljem minimizacije troškova rada mikromreže s vremenskim korakom od 1 sata i duljinom horizonta planiranja od 6 do 96 sati.

Niži sloj je realiziran kao kvadratni *online* optimizacijski problem s ciljem minimizacije korektivnih mjera nastalih uslijed promjene u prognozama ulaznih parametara s vremenskim korakom od 5 minuta. Predstavljeni sustav ne integrira električka ograničenja mikromreže (jednadžbe tokova snaga), ne omogućuje izoliran pogon mikromreže, ne koristi metode za predviđanje ulaznih parametara (smatraju se unaprijed poznatim), niti integrira dodatni (rezervni) izvor napajanja (upravljivi generator) te koristi jednostavni matematički model baterijskog sustava pohrane energije.

Autori u [47] su predstavili dvoslojni sustav upravljanja energijom koji u prvom sloju koristi mješovito cjelobrojni linearni *online* optimizacijski problem s ciljem minimizacije troškova rada mikromreže za sljedećih 24 sata s vremenskim korakom od 1 sata. U nižem sloju koristi Lagrangeovu formulaciju (bez optimizacijskog postupka) za minimizaciju korektivnih mjera uslijed promjena u prognozama ulaznih parametara s vremenskim korakom od 5 minuta. Model ne integrira upravljiva trošila, ne koristi metode za predviđanje ulaznih parametara (smatra se da su unaprijed poznati), ne omogućuje izoliran pogon i ne integrira električka ograničenja (jednadžbe tokova snaga).

3. Unaprijeđeni dvoslojni adaptivni sustav upravljanja energijom mikromreže

U ovom poglavlju opisani su područje i strategija istraživanja, korišteni optimizacijski okvir te optimizacijske metode primijenjene u optimizacijskim problemima pojedinih slojeva sustava upravljanja energijom.

3.1. Područje i strategija istraživanja

Iscrpnim pregledom literature 2. poglavlju određuje se uže područje istraživanja ove doktorske disertacije. Na temelju proučene literature iz ovog područja može se donijeti nekoliko općih zaključaka oko obilježja koji su dosad najmanje istraživani i gdje postoji potencijal za napredak. Velik broj pregledanih sustava upravljanja energijom ne omogućuju izoliran (otočni) pogon mikromreže u odnosu na nadređenu elektroenergetsku mrežu što se ujedno veže i na tipove izvora električne energije koji se modeliraju u literaturi. Iako većina njih integrira neki oblik postrojenja za proizvodnju električne energije iz obnovljivih izvora, velik broj ne modelira dodatni upravljivi izvor napajanja koji posebnu ulogu izvršava kod izoliranog (otočnog) pogona mikromreže u pogledu osiguranja veće pouzdanosti napajanja. Najčešći tip mikromreža koji se susreće u literaturi, a i u praksi, su izmjenične (AC) mikromreže zbog već postojeće infrastrukture. U ovom istraživanju se stoga planira modelirati sustav upravljanja energijom koji omogućuje i umrežen i izoliran (otočni) pogon izmjenične (AC) mikromreže zajedno s dodatnim izvorom napajanja u obliku upravljivog generatora.

Osim upravljivosti izvora električne energije, osnovno obilježje mikromreže je i upravljivost potrošnjom električne energije. Pregledom literature je utvrđeno da velik broj sustava upravljanja energijom mikromreža ne modelira neki oblik upravljivih trošila. U literaturi su prisutna dva pristupa modeliranju upravljive potrošnje električne energije, sustavi upravljanja energijom mikromreža koji modeliraju skup (agregiranje) upravljivih trošila i sustavi koji modeliraju svako pojedino trošilo. Niti jedno istraživanje ne detaljizira na koji način se može postići skupno upravljanje potrošnjom električne energije više upravljivih trošila. Ovo obilježje mikromreže u istraživanju se planira ostvariti kroz detaljnije modeliranje različitih

tipova upravljivih trošila.

Ukoliko se analizira zadnji tip upravljivih (fleksibilnih) elemenata mikromreža, sustave pohrane električne energije, najčešće se koriste olovno-kiselinske ili u posljednje vrijeme i litij-ionske sekundarne baterije kod kojih je također utvrđen velik potencijal za napredak koji se želi ostvariti u ovom istraživanju. Iako se u ovakvim studijama, gdje se koriste baterijski sustavi pohrane energije velikih energetskih kapaciteta i snaga, koristi pojednostavljen matematički model koji ne modelira kemijske i električne procese na razini baterijskog članka, u literaturi se opaža velik broj pojednostavljena i aproksimacija prilikom modeliranja istog. Većina modela sustava pohrane električne energije koristi vrlo jednostavan matematički model, ne uzimaju ograničenja snage punjenja ili pražnjenja baterija, ne modeliraju dvosmjerni pretvarač energetske elektronike niti njegovu funkcijsku ovisnost učinkovitosti o trenutnom opterećenju niti degradaciju baterije kao posljedica kalendarskog i cikličkog starenja. Prema tome, model baterijskog sustava pohrane energije planira se unaprijediti kombinirajući više pogonskih ograničenja i aspekata u radu istog.

Ako se promatra tržišno okruženje u koje je mikromreže integrirana, u literaturi se pronalaze različita rješenja od integracije u maloprodajno tržište kao krajnjeg kupca do integracije kao sudionika u veleprodajnim tržištima električne energije. Kod integracije mikromreže u veleprodajno tržište, većina sustava upravljanja energijom mikromreža smatra da mikromreža sudjeluje kao preuzimatelj cijena uz unaprijed poznate cijene na tržištu dan unaprijed, a tek nekolicina ih sudjeluje u unutardnevnom tržištu u slučaju odstupanja planiranog pogona. Problem integracije mikromreže kao sudionika na veleprodajnim tržištima električne energije je minimalna instalirana snaga (veličina izgradnje) mikromreže potrebna za sudjelovanje na ovim oblicima tržišta električne energije. Većina modeliranih mikromreža u literaturi ne zadovoljava ovaj uvjet.

Ostatak pregledanih sustava upravljanja energijom mikromrežu integrira u maloprodajno tržište kao krajnjeg kupca pomoću višetarifnih sustava naplate električne energije tako da cijene odražavaju trenutnu potražnju za električnom energijom, iako su prisutni i primjeri s dinamičkim cijenama kod kojih se cijene mijenjaju češće u odnosu na višetarifne sustave. Većina ovih sustava modelira iste jedinične cijene za smjer preuzimanja i smjer predaje električne energije iz/u nadređenu elektroenergetsku mrežu što se u praksi sve rjeđe susreće, posebice u regulatornim okvirima za slučaj krajnjih kupaca s vlastitom proizvodnjom kod kojih se pomoću niskih cijena penalizira predaja energije u mrežu i potiče samopotrošnja. Kod modeliranja troška za preuzetu odnosno predanu energiju u mrežu, većina istraživanja ne uzima u obzir naknadu za angažiranu snagu koja može imati veliki utjecaj na profil razmjene energije između mikromreže i nadređene elektroenergetske mreže, a i na samo planiranje pogona mikromreže. U ovom istraživanju planira se implementirati trenutna regulativa za

krajnjeg kupca s vlastitom proizvodnjom s detaljno definiranim stavkama naplate električne energije i uvrštavanjem troška (naknade) za angažiranu snagu.

Svaki optimizacijski problem sadržan u sustavima upravljanja energijom mikromreža zahtijeva ulazne podatke. Ulazni podaci najčešće predstavljaju tehničke karakteristike modela elemenata mikromreže i profile potrošnje električne energije mikromreže, profile ulaznih/izlaznih veličina za postrojenja na obnovljive izvore energije i profile cijena električne energije ovisno o obliku tržišta u koje je mikromreža integrirana za diskretizirano vremensko razdoblje u budućnosti. Većina istraživanja u literaturi ne koristi niti jednu metodu ili algoritam za predviđanje profila potrošnje električne energije odnosno ulaznih/izlaznih veličina za postrojenja na obnovljive izvore energije, nego se smatraju da su unaprijed poznati za određeno razdoblje u budućnosti. Kako je poznato da ulazni podaci u optimizacijske probleme u obliku prognoza bitno mogu utjecati na optimalnost pogona, ova pretpostavka može imati veliki utjecaj na kvalitetu rješenja optimizacijskog problema. U ovom istraživanju se prema tome planiraju primijeniti metode odnosno algoritmi za predviđanje ulaznih parametara u optimizacijske probleme kako bi se povećala realnost modela i bolje ocijenila otpornost razvijenog sustava upravljanja energijom na promjene odnosno nesigurne parametre.

Diverzificiranost mogućih rješenja mikromreža opravdavaju velik broj optimizacijskih okvira i različite tipove optimizacijskih problema u literaturi. Nesigurnost procjene ulaznih podataka u optimizacijske probleme (prognoze) često se zanemaruje prilikom modeliranja, stoga se u literaturi susreće velik broj sustava upravljanja energijom mikromreža s *offline* optimizacijom koja se izvršava samo jedanput i to prije početka promatranog horizonta planiranja na osnovu unaprijed poznatih prognoza nesigurnih parametara. U fokusu ove disertacije su optimizacijski okvir koji omogućuju veću otpornost na promjene tijekom optimizacijskog problema. Ovakvi okviri redovito koriste *online* optimizaciju, a najčešći pristup koji se nalazi u literaturi je strategija pomičnog (klizajućeg) horizonta. Promotre li se dvije osnovne karakteristike optimizacijskih problema koji se koriste za kratkoročno planiranje pogona mikromreža, a to su duljina horizonta planiranja i duljina vremenskog koraka optimizacije, može se primijetiti njihova suprotstavljenost. Rješenje ovog problema planira se realizirati pomoću rasčlanjivanja problema kratkoročnog planiranja pogona na više međusobno povezanih optimizacijskih problema (slojeva) čime se dobivaju optimizacijski problemi različitih karakteristika koji se nazivaju višeslojni sustavi upravljanja energijom mikromreža.

U pogledu optimizacijskih metoda korištenih u literaturi, najčešće se primjenjuju metode matematičkog programiranja odnosno mješovito cjelobrojno linearno programiranje. Razlog čestog korištenja ove metode je kompromis između računalne složenosti metode i razine realnosti modela. Linearnost modela omogućuje bržu optimizaciju što omogućuje primjenu *online* optimizacijskih okvira, a u isto vrijeme se koristi velik broj pojednostav-

ljenja i aproksimacija nelinearnih ovisnosti prilikom modeliranja te je upitno pronalaženje globalnog rješenja problema, ako je prisutno više lokalnih minimuma. Nadalje, u literaturi su prisutne i metode inteligentnog pretraživanja prostora rješenja (metode približenja globalnom optimumu) čije su prednosti mogućnost nepoznavanja karakteristika funkcije cilja, realnije modeliranje s puno manje aproksimacija i pojednostavljenja, manja vjerojatnost zapinjanja u lokalnim minimumima i pronalaženje rješenja bliskih globalnom. Glavni nedostatak ovih metoda su dulje vrijeme izvršavanja procesa optimizacije i utjecaj parametara metode na kvalitetu rješenja. Promatrajući obilježja ovih metoda u pogledu kratkoročnog planiranja pogona mikromreže, primjena ovih metoda omogućuje uvrštavanje električkih ograničenja mikromreže pomoću jednadžbi tokova snaga čime se dobiva model mikromreže bez aproksimacija.

Analizirajući oprečne karakteristike optimizacijskih problema (duljina horizonta planiranja i duljina vremenskog koraka) i navedenih optimizacijskih metoda, nameće se rješenje primjenom obje metode u pogledu dvoslojnog sustava upravljanja energijom mikromreže. U prvom sloju primijenit će se metoda prikladna za dulji horizont planiranja i dulji vremenski korak optimizacije uz jednostavnije modeliranje mikromreže čime će se postići otpornost na promjene u budućnosti, a u nižem sloju će se primijeniti metoda prikladna za kraći horizont planiranja i kraći vremenski korak optimizacije poboljšavajući otpornost na promjene u bliskoj budućnosti uz realnije modeliranje mikromreže primjenom jednadžbi tokova snaga.

S obzirom na sveobuhvatnu analizu literature utvrđeno je da niti jedno istraživanje ne obuhvaća sva moguća gledišta, stoga se istraživanje u ovoj disertaciji usmjerava na ostvarenje sljedećih znanstvenih doprinosa:

- Razvoj unaprijeđenog dvoslojnog adaptivnog sustava upravljanja energijom mikromreže realiziranog u višem sloju pomoću mješovitog cjelobrojnog linearnog programiranja temeljenog na strategiji pomičnog horizonta s korektivnim djelovanjem i ciljem maksimizacije dobiti, a u nižem sloju kao nelinearni optimizacijski problem u kosimulacijskom okruženju u gotovo stvarnom vremenu s ciljem minimizacije korektivnih mjera nastalih uslijed promjena ulaznih parametara;
- Razvoj unaprijeđenog modela baterijskog sustava pohrane energije kombiniranjem učinkovitosti dvosmjernog energetskog pretvarača ovisne o opterećenju, energetskog modela punjenja baterije, modeliranja cikličkog i kalendarskog starenja baterije i valorizacijom pohranjene energije;
- Vrednovanje razvijenog sustava upravljanja energijom planiranjem kratkoročnog pogona testne mikromreže.

3.2. Optimizacijski okvir sustava upravljanja energijom mikromreže

Otpornost i adaptivnost promatranog sustava upravljanja energijom na promjene koje u optimizacijski problem unose nesigurni ulazni parametri (prognoze) ogleda se u optimizacijskom okviru temeljenom na strategiji pomičnog (klizajućeg) horizonta s korektivnim djelovanjem. Ovaj optimizacijski okvir pripada skupini *online* optimizacije jer se optimizacijski postupak izvršava svaki vremenski korak ili kad god su dostupne nove prognoze ulaznih parametara. Slojevi sustava upravljanja energijom međusobno su povezani spojnim varijablama (engl. *Linking variables*) čime se također postiže svojstvo korektivnog djelovanja.

Grafički prikaz principa rada strategije pomičnog horizonta s korektivnim djelovanjem za tri iteracije optimizacije vidljiv je na slici 3.1 [18]. Osnovna obilježja strategije pomičnog horizonta su horizont predviđanja (engl. *Prediction horizon - PH*) za koji se predviđaju ulazni parametri u optimizacijske probleme (slojeve), horizont planiranja (engl. *Scheduling horizon - SH*) za koji se pogon mikromreže optimira i upravljački horizont (engl. *Control horizon - CH*) u kojemu se primjenjuju generirane odluke nakon optimizacijskog postupka. Svaka iteracija procesa odvija se prije trenutka t koji vrijedi za svaku pojedinu iteraciju. Proces počinje unošenjem ulaznih podataka u obliku tehničkih karakteristika modeliranih elemenata mikromreže i ulaznih profila (prognoza) za horizont predviđanja PH_1 koji definiraju početno stanje sustava IS_1. Pogon se optimira za diskretizirano vremensko razdoblje u budućnosti SH_1 na osnovu predviđenih ulaznih parametara u PH_1. Generirane odluke nakon prve iteracije optimizacije primjenjuju se samo za prvi sljedeći horizont upravljanja CH_1. Prije sljedeće iteracije optimizacije vremenski korak se pomiče, a varijable stanja na kraju horizonta upravljanja CH_1 se prosljeđuju kao ulazne varijable koje uz osvježene prognoze za razdoblje PH_2 definiraju stanje sustava IS_2. Slijedi optimizacijski postupak za horizont planiranja SH_2. Isti postupak se ponavlja u sljedećim iteracijama. Prosljeđivanjem varijabli stanja između pojedinih iteracija optimizacije i osvježavanjem prognoza u svakom vremenskom koraku postiže se korektivno djelovanje odnosno otpornost (adaptivnost) na promjene koje u optimizacijske probleme unose nesigurni parametri.

Sustav upravljanja energijom realiziran je kao dvoslojni sustav gdje svaki sloj predstavlja jedan optimizacijski problem, a optimizacijski problemi međusobno su povezani varijablama stanja. Blokovska shema dvoslojnog sustava upravljanja energijom sa svim glavnim dijelovima vidljiva je na slici 3.2. Prognoze ulaznih parametara u optimizacijske probleme za horizont predviđanja PH_i i odluke operatora/korisnika mikromreže predstavljaju ulazne podatke u optimizacijski problem višeg sloja zasnovanog na strategiji pomičnog horizonta. Optimizacijski problem višeg sloja optimira pogon za diskretizirano vremensko razdoblje T

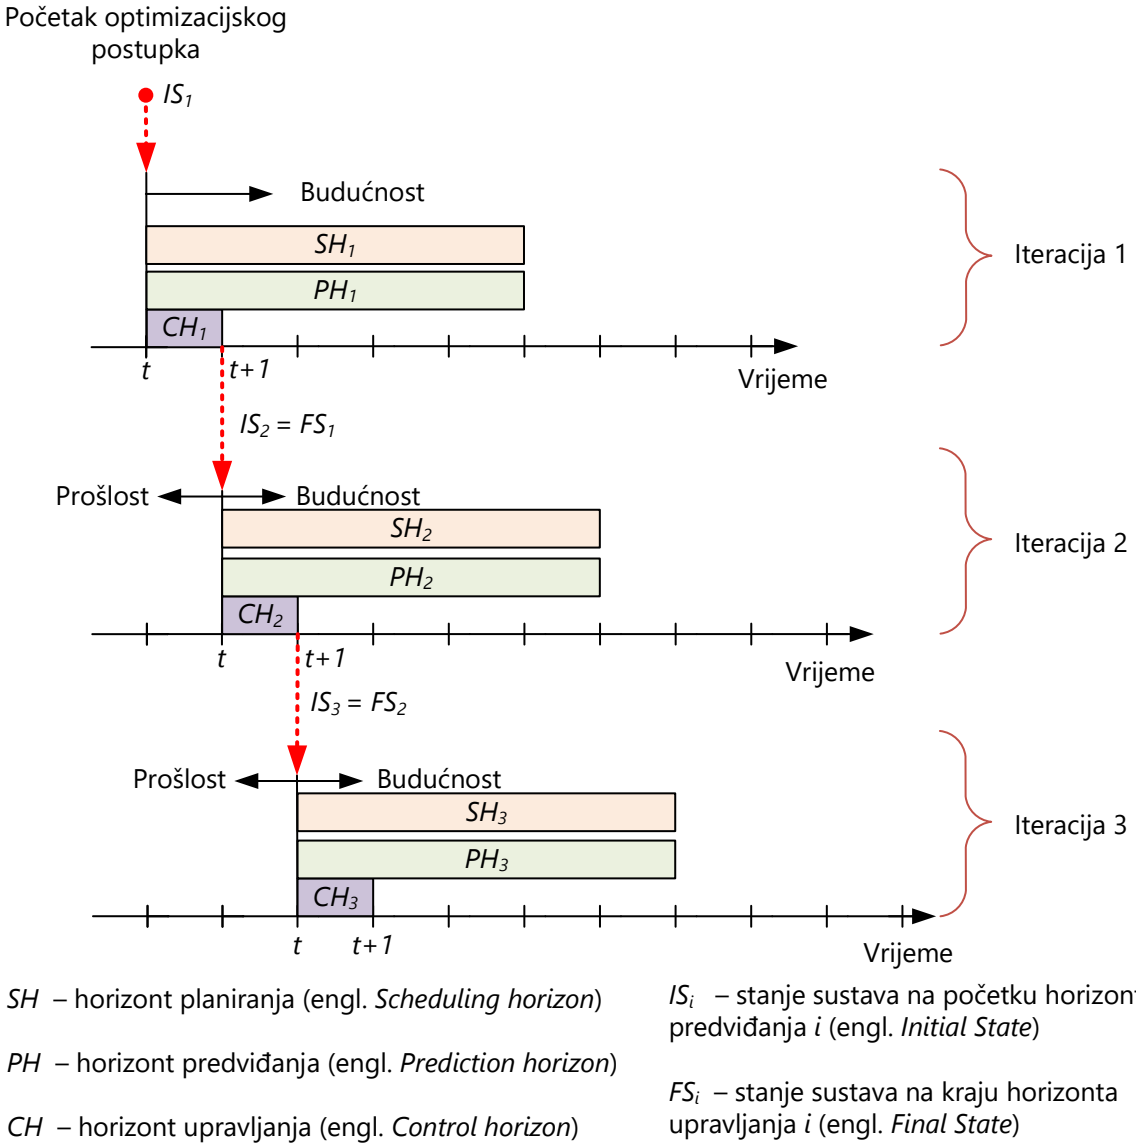

Slika 3.1: *Strategija pomičnog horizonta s korektivnim djelovanjem*

u budućnosti (horizont planiranja SH_i) gdje svaki vremenski korak ima oznaku t. Unutar vremenskog koraka t veličine se smatraju konstantnima (ne mijenjaju se). Varijable odluke generirane za sljedeći horizont upravljanja CH_i služe kao ulazni podaci u niži sloj sustava upravljanja energijom odnosno kao referentne vrijednosti. Na osnovu osvježenih kratkoročnih prognoza ulaznih parametara (za horizont predviđanja koji je jednak horizontu upravljanja višeg sloja CH_i), optimizacijski problem nižeg sloja optimira pogon samo za horizont planiranja koji je jednak horizontu upravljanja višeg sloja CH_i. Horizont planiranja nižeg sloja je diskretiziran na k vremenskih koraka koji su manje duljine od vremenskog koraka višeg sloja t. Varijable stanja u zadnjem vremenskom koraku nižeg sloja K prosljeđuju se kao ulazni podaci u viši sloj, vremenski korak t se povećava za jedan i isti postupak se ponavlja za sljedeću iteraciju optimizacije i.

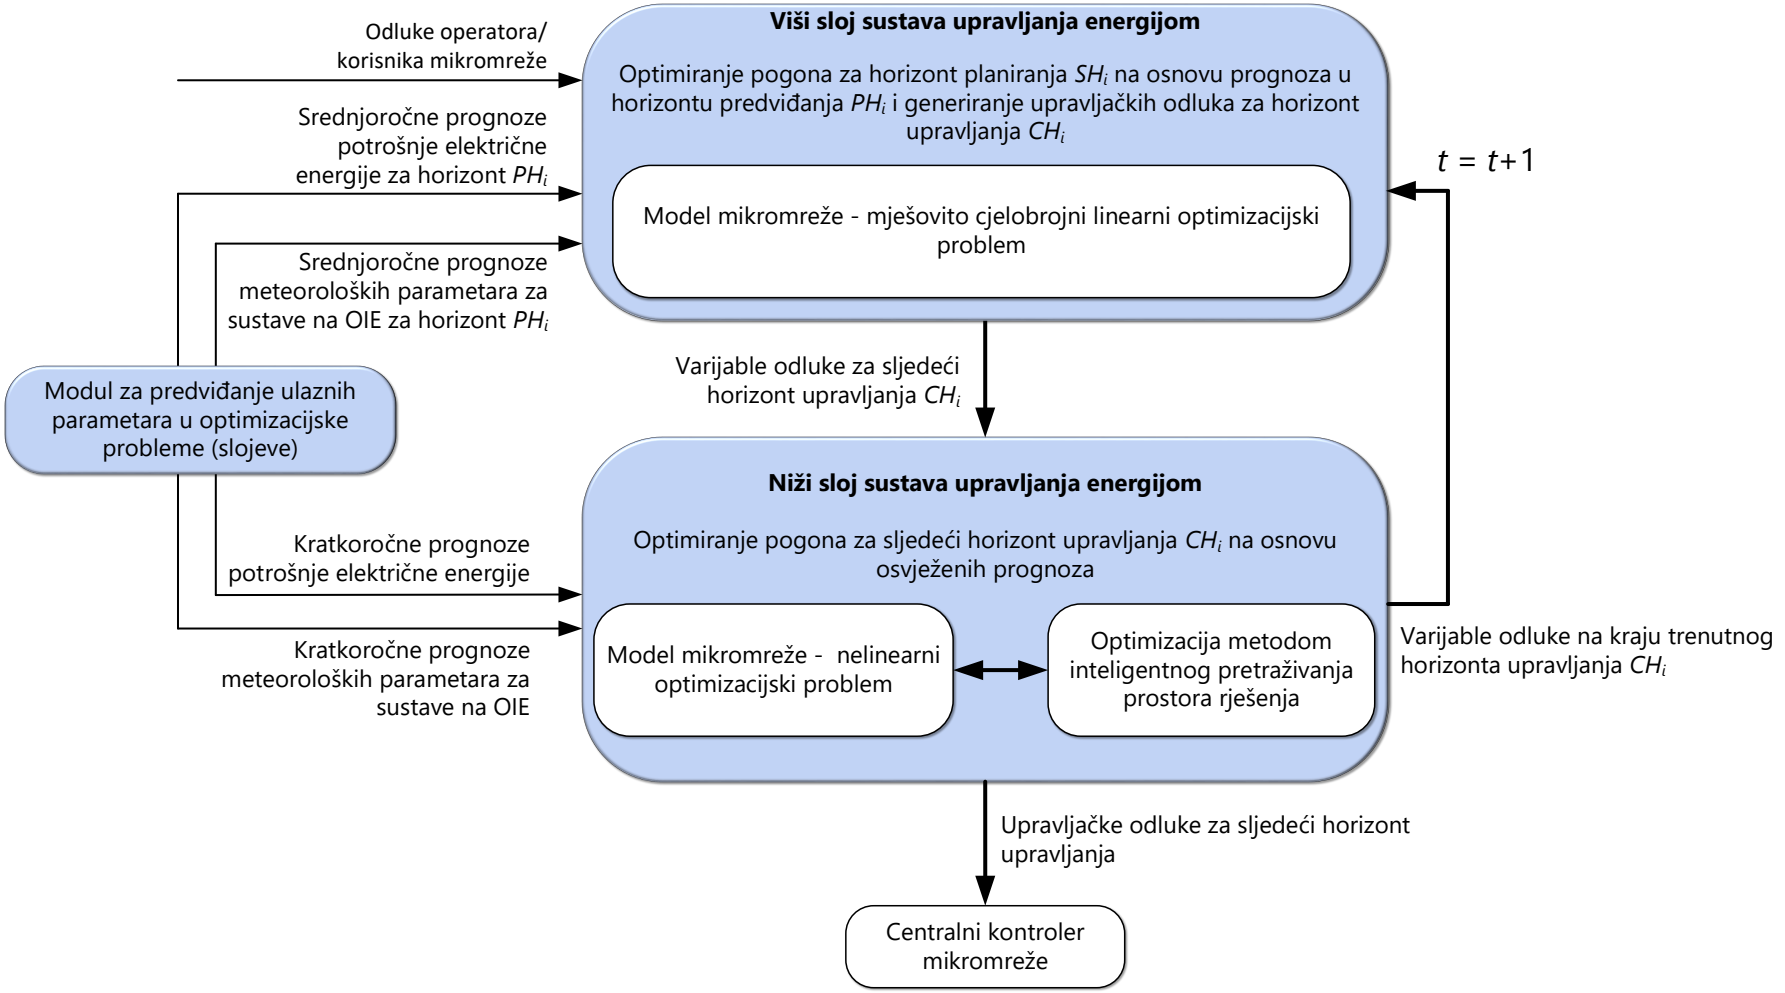

Slika 3.2: *Blokovska shema dvoslojnog adaptivnog sustava upravljanja energijom mikromreže*

3.3. Optimizacijska metoda primijenjena u optimizacijskom problemu višeg sloja sustava upravljanja energijom mikromreže

Optimizacijski problem višeg sloja sustava upravljanja energijom mikromreže je realiziran metodom matematičkog programiranja. Metode matematičkog programiranja numerički rješavaju problem minimizacije ili maksimizacije funkcije cilja uz postavljena ograničenja. Funkcija cilja je funkcija koja se minimizira ili maksimizira, a čija vrijednost ovisi o varijablama. Varijable mogu poprimiti vrijednosti definirane dopuštenim područjem koje predstavlja skup mogućih rješenja optimizacijskog problema s obzirom na postavljena ograničenja. Ograničenja koja se postavljaju mogu se općenito podijeliti na funkcijska ograničenja (u obliku jednadžbi i nejednadžbi) i ograničenja varijabli (limiti varijabli) [78].

Općenito se varijable mogu podijeliti na varijable odluke, varijable stanja, izlazne varijable i radne varijable. S aspekta ulazno-izlaznih podataka varijable odluke (varijable odlučivanja, upravljačke varijable) predstavljaju ulazne varijable. Varijable stanja su varijable optimizacijskog problema čije se vrijednosti traže za postizanje optimuma i predstavljaju njegovo rješenje. Izlazne varijable predstavljaju varijable čije se optimalne vrijednosti traže, a predstavljaju vrijednosti funkcije cilja. Varijable stanja su varijable koje predstavljaju poveznicu između ulaznih i izlaznih varijabli optimizacijskog problema. Njihova vrijednost ovisi o ulaznim varijablama, a o njihovim vrijednostima ovisi vrijednost izlaznih varijabli. Radne varijable (varijable radne točke) predstavljaju varijable okoline optimizacijskog problema za koje vrijedi pronađeno rješenje [74].

Opći oblik optimizacijskog problema može se zapisati izrazom 3-1 u kojemu je x je vektor varijabli, f je funkcija cilja varijabli x koja se želi minimizirati ili maksimizirati, a c je vektor ograničenja varijabli x koja se moraju zadovoljiti. Broj elemenata vektora c ovisi o broju postavljenih ograničenja. U izrazu 3-1 f i c su funkcije varijabli x, a E i I predstavljaju skup indeksa [79].

$$\begin{aligned} &\text{minimiziraj } f(x) \\ &\text{uz ograničenja: } \begin{cases} c_i(x) = 0, & i \in E, \\ c_i(x) >= 0, & i \in I, \end{cases} , x \in \mathbb{R}^n \end{aligned} \tag{3-1}$$

3.3.1. Mješovito cjelobrojno linearno programiranje

Metoda mješovitog cjelobrojnog linearnog programiranja pripada skupini metoda linearnog programiranja. Linearni programi su opisani linearnom funkcijom cilja i linearnim ograničenjima u obliku jednadžbi i/ili nejednadžbi. Opći oblik linearnog optimizacijskog problema može se zapisati izrazom 3-2 u kojima su c i x vektori skupa $\mathbb{R}^n$, b je vektor u skupu $\mathbb{R}^m$, a A je matrica dimenzija $m \times n$ [79].

$$\begin{aligned} &\text{minimiziraj } c^T x \\ &\text{uz ograničenja: } Ax = b \\ &\qquad\qquad\quad x \geq 0 \end{aligned} \tag{3-2}$$

Problem minimizacije može se pretvoriti u problem maksimizacije promjenom predznaka elemenata matrice c čime se dobiva optimizacijski problem - minimiziraj$(-c)^T x$. Postoji velik broj različitih metoda za rješavanje linearnih problema, a dvije najkorištenije su simplex metoda (engl. *Simplex method*) i metoda unutarnje točke (engl. *Interior point method*). Detaljan opis ove dvije metode je dostupan u [79].

Razlika između linearnog i mješovito cjelobrojnog linearnog programiranja je u vrijednostima koje varijable mogu poprimiti. Kod mješovitog cjelobrojnog linearnog programiranja neke varijable mogu poprimiti cjelobrojne vrijednosti. Optimizacijski problem opisuje linearna funkcija cilja i linearna ograničenja u obliku jednadžbi ili nejednadžbi. U višem sloju sustava upravljanja energijom mikromreže koriste se binarne (cjelobrojne) varijable (0 ili 1). Primjena ove metode omogućuje donošenje binarnih odluka kod upravljivih elemenata mikromreže kao što su upravljivi generator (uključenje/isključenje, tehnički minimumi/maksimumi, minimalno vrijeme proizvodnje/prestanka proizvodnje), baterijski sustav pohrane energije (način rada: punjenje ili pražnjenje), upravljiva trošila (odluka o isključenju/uključenju), odluka o preuzimanju ili predaji energije između mikromreže i nadređene elektroenergetske mreže, itd. Opći zapis mješovito cjelobrojnog linearnog optimizacijskog problema prikazan u izrazu 3-3 identičan je zapisu linearnog optimizacijskog problema prikazan u 3-2 uz dodatno ograničenje u posljednjem retku, gdje je $\mathcal{I}$ vektor koji sadržava indekse varijabli s cjelobrojnim vrijednostima [80].

$$\begin{aligned} &\text{minimiziraj } c^T x \\ &\text{uz ograničenja: } Ax = b \\ &\qquad\qquad\qquad\quad x \geq 0 \\ &\qquad\qquad\qquad\quad x_i \in \mathbb{Z}, \forall i \in \mathcal{I} \end{aligned} \tag{3-3}$$

Ako cjelobrojne varijable mogu poprimiti samo binarne vrijednosti (0 ili 1), potrebno je izrazu 3-3 dodati dodatno ograničenje prikazano u izrazu 3-4.

$$0 \leq x_i \leq 1 \tag{3-4}$$

Mješovito cjelobrojni linearni optimizacijski problemi mogu se riješiti pomoću algoritma grananja i ograđivanja (engl. *Branch and bounding*). Kako je originalni optimizacijski problem teško rješiv u izvornom obliku, algoritam dijeli originalni problem na više (jednostavnijih) podproblema koje potom rješava. Postupak rješavanja pomoću ovog algoritama najčešće se prikazuje grafički u obliku stabla s više grana. Algoritam granjanja i ograđivanja odvija se u tri koraka: grananje, ograđivanje i procjenjivanje. Dijeljenje problema odvija se pomoću tehnike grananja (engl. *Branching*) koja kod optimizacijskog problema s binarnim varijablama dijeli skup mogućih rješenja u podskupove gdje određena varijabla u jednom podskupu poprima vrijednost 0, a u drugom podskupu vrijednost 1. Postupak ograđivanja (engl. *Bounding*) određuje granice minimalne ili maksimalne vrijednosti funkcije cilja (ovisno o cilju) svakog podskupa. Najčešći način koji se koristi za određivanje najboljeg rješenja je korištenje pojednostavljenja (engl. *Relaxation*) optimizacijskog problema rješavajući određeni problem uz zanemarenje određenih ograničenja koristeći neku od metoda za rješavanje linearnih optimizacijskih problema. U zadnjem koraku koristi se postupak procjenjivanja (engl. *Fathoming*) kvalitete rješenja svakog podproblema i donošenje odluke hoće li se nastaviti proces grananja ili zaustaviti. Detaljan opis metode grananja i ograđivanja dostupan je u [81].

U praksi su dostupni različiti viši programski jezici u obliku algebarskih jezika za modeliranje (engl. *Algebraic modelling language*) koji se koriste za pretvaranje matematičkog zapisa optimizacijskog problema u računalni kod (AIMMS, AMPL, GAMS, APMonitor, JuMP, LINDO, MathProg, Mosel, Pyomo). Algebarski jezik za modeliranje ne rješava optimizacijski problem nego služi za lakši zapis optimizacijskog problema. Prednost pisanja programskog koda u algebarskim jezicima za modeliranje u odnosu na pisanje programskog koda izravno u programe za numeričko rješavanje (engl. *Solver*) je što algebarski jezici za modeliranje omogućuju raspisivanje optimizacijskog problema u obliku sličnom izvornom algebarskom obliku (pomoću skupova, indeksa, algebarskih izraza, itd.) koji je razumlji-

viji korisnicima. Kako algebarski jezici za modeliranje imaju ugrađena sučelja za različite programe za numeričko rješavanje, to omogućuje lakšu primjenu različitih programa za numeričko rješavanje na isti programski kôd optimizacijskog problema, odnosno nije potrebno pretvarati kod u drugi programski jezik koji razumije program za numeričko rješavanje.

Optimizacijski problem višeg sloja sustava upravljanja energijom mikromreže u disertaciji realiziran je kao mješovito cjelobrojni linearni problem s binarnim varijablama i pretvoren u programski kôd u algebarskom jeziku za modeliranje *Pyomo*. *Pyomo* je algebarski jezik za modeliranje otvorenog koda (engl. *Open-source*) razvijen u višem programskom jeziku *Python* [82,83]. Optimizacijski problem rješava se pomoću programa za numeričko rješavanje *Gurobi* koji je preko sučelja povezan s algebarskim jezikom za modeliranje *Pyomo*. *Gurobi* je komercijalni program za numeričko rješavanje linearnih, kvadratnih, kvadratno-ograničenih, mješovito cjelobrojnih linearnih, mješovito cjelobrojnih kvadratnih i mješovito cjelobrojno kvadratno-ograničenih optimizacijskih problema dostupan u besplatnoj akademskoj licenci [84].

3.4. Optimizacijska metoda primijenjena u optimizacijskom problemu nižeg sloja sustava upravljanja energijom mikromreže

Optimizacijski problem nižeg sloja sustava upravljanja energijom realiziran je kao nelinearni *black-box* optimizacijski problem u kosimulacijskom okruženju. Kosimulacijsko okruženje realizirano je povezivanjem optimizacijske metode inteligentnog pretraživanja prostora rješenja (metaheuristička optimizacijska metoda) i simulacijskog alata za modeliranje i analizu elektroenergetskih mreža. Razlog korištenja upravo ove skupine optimizacijskih metoda je što omogućuju rješavanje optimizacijskih problema bez poznavanja osobina funkcije cilja (linearna/nelinearna, eksplicitna/neeksplicitna, derivabilna/nederivabilna, tipovi ograničenja, itd.), a što ujedno omogućuje i rješavanje tzv. *black-box* optimizacijskih modela. U ovom kosimulacijskom okruženju *black-box* optimizacijski problem predstavlja model mikromreže razvijen u simulacijskom alatu za modeliranje i analizu elektroenergetskog sustava. Budući da ovi alati imaju razvijene modele tipičnih elemenata elektroenergetskog sustava i imaju implementirane jednadžbe tokova snaga, omogućuju razvijanje modela mikromreže s električkim ograničenjima (primjenom jednadžbi tokova snaga) čime se dobiva model mikromreže bez aproksimacija, što je jedan od ciljeva istraživanja ove disertacije. Implementacijom jednadžbi tokova snaga optimizacijski model postaje nelinearan. Nedostatak optimizacijskih metoda s inteligentnim pretraživanjem prostora rješenja je dulje vrijeme izvršavanja procesa optimizacije zbog čega je ova optimizacijska metoda prikladna za implementaciju u nižem

sloju sustava upravljanja energijom mikromreže u kojemu se proces optimizacije izvršava korak-po-korak za kratki horizont planiranja, čime se smanjuje računalna složenost modela, a koji je jednak horizontu upravljanja CH_i višeg sloja prema slici 3.2.

Blokovska shema kosimulacijskog okruženja nižeg sloja sustava upravljanja energijom vidljiva je na slici 3.3. Razmjena informacija u kosimulacijskom okruženju započinje optimizacijskom metodom inteligentnog pretraživanja prostora rješenja koja na svom izlazu generira varijable odluke s obzirom na postavljenu funkciju cilja i ograničenja. Generirane varijable odluke predstavljaju ulazne podatke potrebne za proračun tokova snaga unutar mikromreže realizirane kao model u simulacijskom alatu za modeliranje i analizu elektroenergetskih mreža. Naposlijetku, rezultati proračuna tokova snaga služe kao ulazni podaci u optimizacijsku metodu pomoću kojih se određuje vrijednost funkcije cilja čime se zatvara krug razmjene informacija. Opisom principa razmjene informacija u kosimulacijskom okruženju može se zaključiti da i optimizacijska metoda i simulacijski alat za modeliranje i analizu elektroenergetskih mreža zahtijevaju sučelja jedan prema drugome.

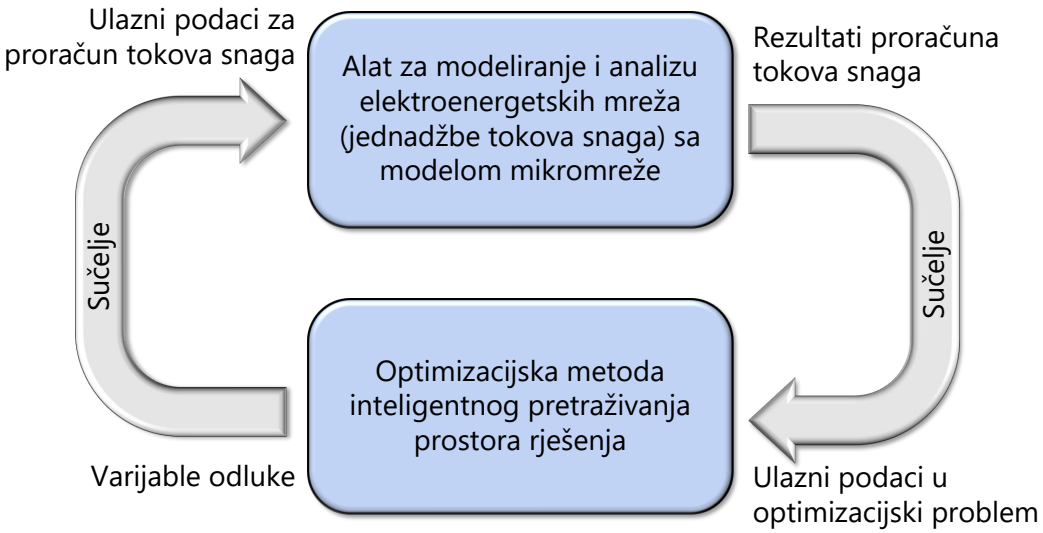

Slika 3.3: *Blokovska shema kosimulacijskog okruženja nižeg sloja sustava upravljanja energijom mikromreže*

U optimizacijskom problemu nižeg sloja sustava upravljanja energijom ove disertacije koristi se optimizacija rojem čestica kao metoda za pretraživanje prostora rješenja. Optimizacija rojem čestica (engl. *Particle Swarm Optimization* - PSO) je stohastička optimizacijska metoda (algoritam) koja pripada metodama inteligencije roja (engl. *Swarm intelligence*) temeljena na populaciji čestica (jedinki) inicijalno predstavljena u [85]. Metoda simulira društveno ponašanje prirodnih organizama kao što su jata ptica i riba u potrazi za hranom.

3.4.1. Optimizacija rojem čestica

O ovom poglavlju se opisuje algoritam metode optimizacije rojem čestica. Roj (populacija) u osnovnom obliku sastoji se od N čestica koje se kreću kroz D-dimenzionalni prostor pretrage. Svaka čestica i kandidat je za rješenje optimizacijskog problema i predstavljena je vektorom x_i u prostoru rješenja. Svakoj čestici pridruženo je svojstvo brzine i položaja koja određuju smjer kretanja dok uspjeh nekih čestica određuje ponašanje ostalih čestica u roju (populaciji). Svaka čestica prilagođava svoj položaj x_i prema globalnom optimumu s obzirom na dva faktora: najbolji vlastiti položaj (engl. *Personal best - pbest*$_i$) definiran vektorom $p_i = (p_{i1}, p_{i2}, ..., p_{iD})$ i položaj najbolje čestice u roju (engl. *Global best - gbest*$_i$) ili u okolini čestice koje je podskup roja (engl. *Local best - lbest*) definiran vektorom $p_g = (p_{g1}, p_{g2}, ..., p_{gD})$. Vektor $(p_g - x_i)$ predstavlja razliku između trenutnog položaja čestice i i najboljeg položaja roja ili okoline promatrane čestice [86].

Prema tome, svaku česticu opisuju sljedeća svojstva [86]:

- Vektor x pohranjuje trenutni položaj čestice u prostoru pretrage;
- Vektor p pohranjuje položaj najbolje čestice u roju;
- Vektor v sadržava gradijent (smjer, brzina) svake čestice bez vanjskih utjecaja na njeno kretanje;
- Dva faktora dobrote (engl. *Fitness*): *x-fitness* određuje dobrotu vektora x, a *p-fitness* određuje dobrotu vektora p.

Operacije koje se vrše nad svakom česticom u roju mogu se podijeliti na sljedeće postupke [86]:

- **Osvježavanje brzine čestice** koja određuje intenzitet promjene ponašanja čestice prema izrazu: 3-5

$$v_i(t) = v_i(t-1) + \rho_1 C_1 \times (p_i - x_i(t-1)) + \rho_2 C_2 \times (p_g - x_i(t-1)) \tag{3-5}$$

  gdje su ρ_1 i ρ_2 dvije nasumične varijable koje poprimaju vrijednosti između 0 i 1. Konstanta C_1 predstavlja stupanj uvažavanja individualnog iskustva (engl. *Cognitive component*), a konstanta C_2 predstavlja stupanj uvažavanja informacija (znanja) čestica u okolini ili cijelog roja (engl. *Social component*). Brzina čestice određuje smjer i udaljenost koju će prijeći prema slici 3.4. Ovaj izraz opisuje princip društvenog ponašanja čovjeka gdje društveno-psihološke tendencije pojedinca određuju uspješnost ostalih pojedinaca u okolini ili populaciji. Brzina čestice v_i ograničena je u rasponu $[-V_{\max}, +V_{\max}]$ kako ne bi napustila prostor pretrage kao posljedica nasumičnosti sustava.

Kako bi se ograničio utjecaj brzine čestice u prošloj iteraciji $(t-1)$ na brzinu čestice u trenutnoj iteraciji t u izraz za brzinu čestice (3-5) dodaje se inercija čestice w_i čime algoritam dobiva predmetak inercijski (engl. *Weighted particle swarm optimization*), a brzina se računa prema izrazu 3-6. Inercija čestice predstavlja kompromis između globalnog i lokalnog pretraživanja prostora rješenja.

$$v_i(t) = w_i \times v_i(t-1) + \rho_1 C_1 \times (p_i - x_i(t-1)) + \rho_2 C_2 \times (p_g - x_i(t-1)) \tag{3-6}$$

- **Osvježi položaj čestice** prema izrazu 3-7:

$$x_i(t) = x_i(t-1) + v_i(t) \tag{3-7}$$

- **Osvježi najbolji vlastiti položaj čestice i položaj najbolje čestice u roju/okolini** prema izrazima 3-8 i 3-9 (za slučaj minimizacije funkcije cilja):

$$\text{Ako je } f(x_i) < pbest_i \longrightarrow p_i = x_i \tag{3-8}$$

$$\text{Ako je } f(x_i) < gbest_i \longrightarrow g_i = x_i \tag{3-9}$$

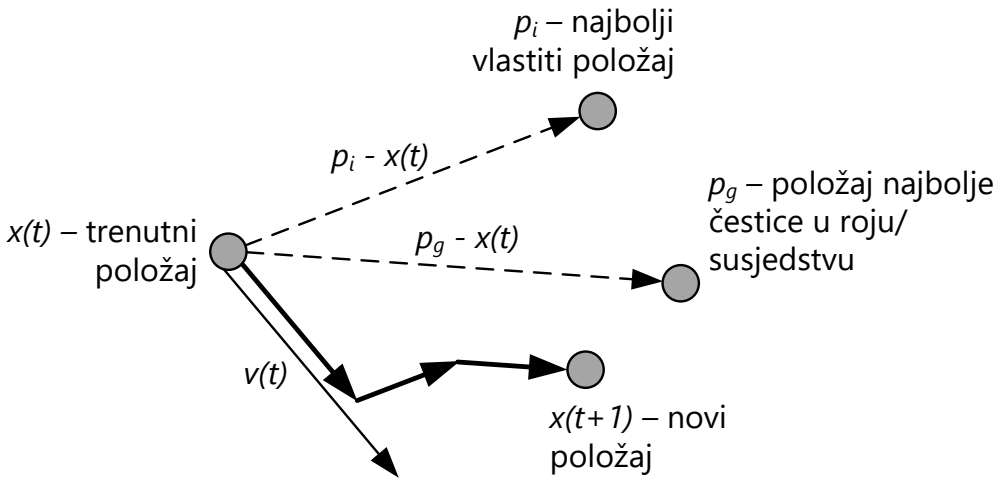

Slika 3.4: *Određivanje položaja i osvježavanje brzine čestice*

U ovoj disretaciji kosimulacijsko okruženje realizira se povezivanjem optimizacijskog paketa s ugrađenim metodama inteligentnog pretraživanja prostora rješenja *PyGMO* (engl. *the Python Parallel Global Multiobjective Optimizer*) i simulacijskog alata za modeliranje i analizu elektroenergetskih sustava *OpenDSS* (engl. *Open Distribution System Simulator*). *PyGMO* je optimizacijski paket otvorenog koda inicijalno razvijen u Europskoj svemirskoj

agenciji (engl. *European Space Agency*) [87] koji implementira razne optimizacijske metode s inteligentnim pretraživanjem prostora rješenja razvijen u višem programskom jeziku *Python*. Inicijalna verzija razvijena je u programskom jeziku *C++* pod imenom *Pagmo* (engl. *Parallel Global Multiobjective Optimization*), a kasnije je razvijena inačica i za *Python*.

PyGMO ima ugrađene različite metode inteligentnog pretraživanja prostora rješenja nadahnute ponašanjima i pojavama u prirodi. Primjeri dostupnih metoda (algoritama) su diferencijalna evolucija, optimizacija rojem čestica, genetski algoritam, simulirano kaljenje, umjetna kolonija pčela u osnovnim oblicima i njihovim inačicama, a paket omogućuje i definiranje vlastitih inačica algoritma [88]. Laka dostupnost više metoda (algoritama) omogućuje primjenu različitih metoda na isti optimizacijski problem. Cilj istraživanja ove disertacije nije unaprijeđenje optimizacijske metode nego unaprijeđenje optimizacijskog okvira i oblika optimizacijskog problema (funkcije cilja i njenih ograničenja). Prema tome, za rješavanje optimizacijskog problema nižeg sloja sustava upravljanja energijom mogla se koristiti bilo koja optimizacijska metoda navedena iznad. Paket također omogućuje usporedno provođenje procesa pretraživanja prostora rješenja istodobno s više rješenja što dovodi do brže konvergencije prema optimumu.

3.4.2. Simulacijski alat za modeliranje i analizu elektroenergetskih mreža *OpenDSS*

Izbor simulacijskog alata (softvera) za modeliranje i analizu elektroenergetskih sustava u kosimulacijskom okruženju ponaprije ovisi o karakteristikama alata s obzirom na mogućnost povezivanja s vanjskim softverima. *OpenDSS* je simulacijski alat za modeliranje i analizu elektroenergetskih mreža otvorenog koda razvijen od *EPRI*-a (engl. *Electric Power Research Institute*) [89] opremljen aplikacijskim programskim sučeljima (engl. *Application Programming Interface* - API) prema većini najkorištenijih programskih alata za znanstveno-istraživački rad kao što su *MATLAB, Python, C++* što omogućuje realizaciju predloženog kosimulacijskog okruženja u ovoj disertaciji.

OpenDSS vrši analizu elektroenergetskih mreža u frekvencijskoj domeni te je inicijalno razvijen za analizu utjecaja distribuiranih izvora na pogon distribucijskih elektroenergetskih mreža. Alat omogućuje vršenje simulacija u vremenskoj domeni s različitim intervalima promatranja i frekvencijama uzorkovanja za lakše planiranje razvoja distribucijskog sustava i studija utjecaja promjenjive proizvodnje električne energije iz distribuiranih izvora. S obzirom na vremensku domenu alat omogućuje vršenje sljedećih analiza: *snapshot* način rada (stacionarni tokovi snaga), *daily* način rada (24 satni interval), *yearly* način rada (8760 satni interval) i *duty cycle* način rada za simulaciju u vremenu od 1 do 5 sekundi. Osnovna struktura *OpenDSS* alata vidljiva je na slici 3.5. Korisnički DLL (engl. *Dynamic-link library*)

modeli prikazani na slici 3.5 omogućuju razvoj vlastitih modela elemenata elektroenergetskog sustava [90].

U realiziranom kosimulacijskom okruženju koristi se COM (engl. *Component Object Model*) sučelje za viši programski jezik *Python* čime se omogućuje dvosmjerna komunikacija *OpenDSS*-a i optimizacijskog paketa *PyGMO*. Preko COM sučelja u *Python*-u su dostupne sve funkcionalnosti dostupne u softveru kao što su definiranje novih modela mreže, rekonfiguracija mreže, modificiranje postojećih elemenata, mijenjanje njihovih postavki i parametara, vršenje različitih simulacija i analiza te uvoženje rezultata iz *OpenDSS*-a. Više o alatu *OpenDSS* dostupno je u korisničkom priručniku u [90].

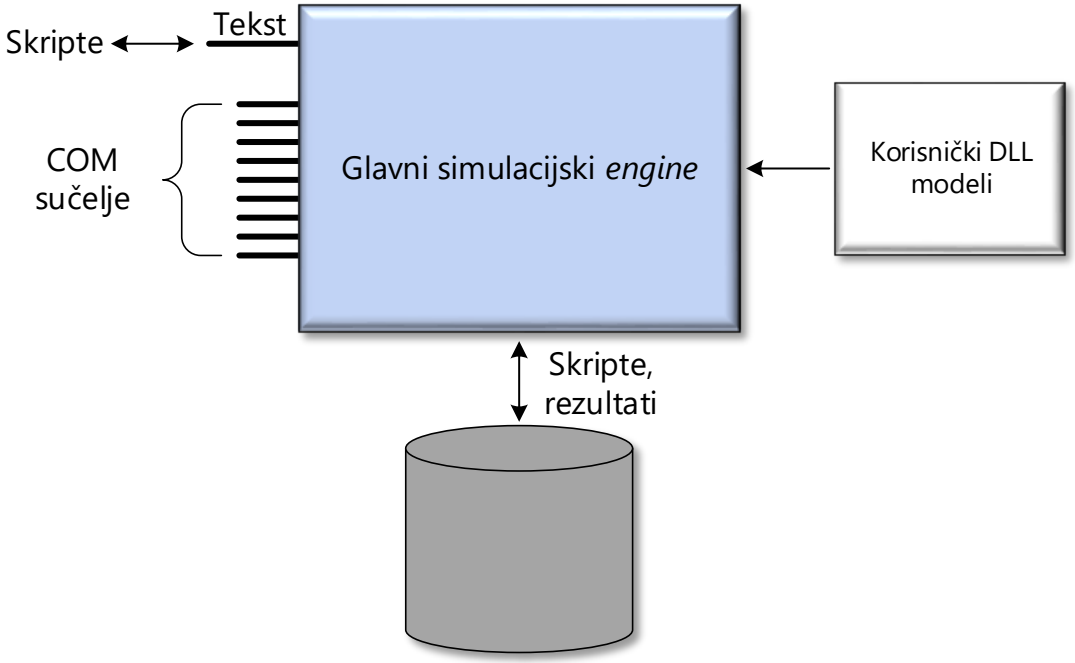

Slika 3.5: *Struktura OpenDSS alata*

4. Optimizacijski problemi dvoslojnog sustava upravljanja energijom mikromreže

U ovom poglavlju opisani su optimizacijski problemi pojedinih slojeva sustava upravljanja energijom mikromreže. Kako su modeli elemenata mikromreže u optimizacijskim problemima pojedinih slojeva sustava upravljanja energijom isti, u poglavlju 4.7 opisana su dodatna ograničenja implementirana u optimizacijskom problemu nižeg sloja u odnosu na optimizacijski problem višeg sloja sustava upravljanja energijom zajedno s pripadajućom funkcijom cilja. Naposlijetku, u poglavlju 4.8 dan je opis korištenih metoda za predviđanje ulaznih parametara u optimizacijske probleme dvoslojnog sustava upravljanja energijom mikromreže.

Optimizacijski problem višeg sloja sustava upravljanja energijom kratkoročno planira pogon mikromreže s ciljem maksimizacije dobiti. Sastoji se od više matematičkih modela različitih tipova elemenata mikromreže koji će biti opisani u nastavku. Matematički zapis modela elementa mikromreže ima linearne funkcijske ovisnosti te koriste binarne varijable kako bi se mogao razviti programski kôd mješovito cjelobrojnog linearnog optimizacijskog problema. Sve varijable i parametri pojedinih modela elemenata mikromreže pripadaju skupu realnih brojeva jednakih ili većih od nule, osim ako je drukčije naznačeno. Opis korištene optimizacijske metode dostupan je u poglavlju 3.3. Primjenom ove metode matematičkog programiranja mikromreža se modelira kao jednosabirnički sustav kod kojeg se smatra da su svi elementi mikromreže spojeni na jednu sabirnicu, promatraju se samo tokovi radne snage, a električka ograničenja mikromreže se zanemaruju.

Optimizacijski problem modelira sljedeće tipove elemenata mikromreže:

- Mreža (mjesto priključka mikromreže na nadređenu elektroenergetsku mrežu);
- Baterijski sustav pohrane energije;
- Fotonaponski sustav;
- Upravljivi generator;
- Trošila električne energije.

Blokovska shema mikromreže modelirane kao jednosabirnički sustav s različitim elementima vidljiv je na slici 4.1.

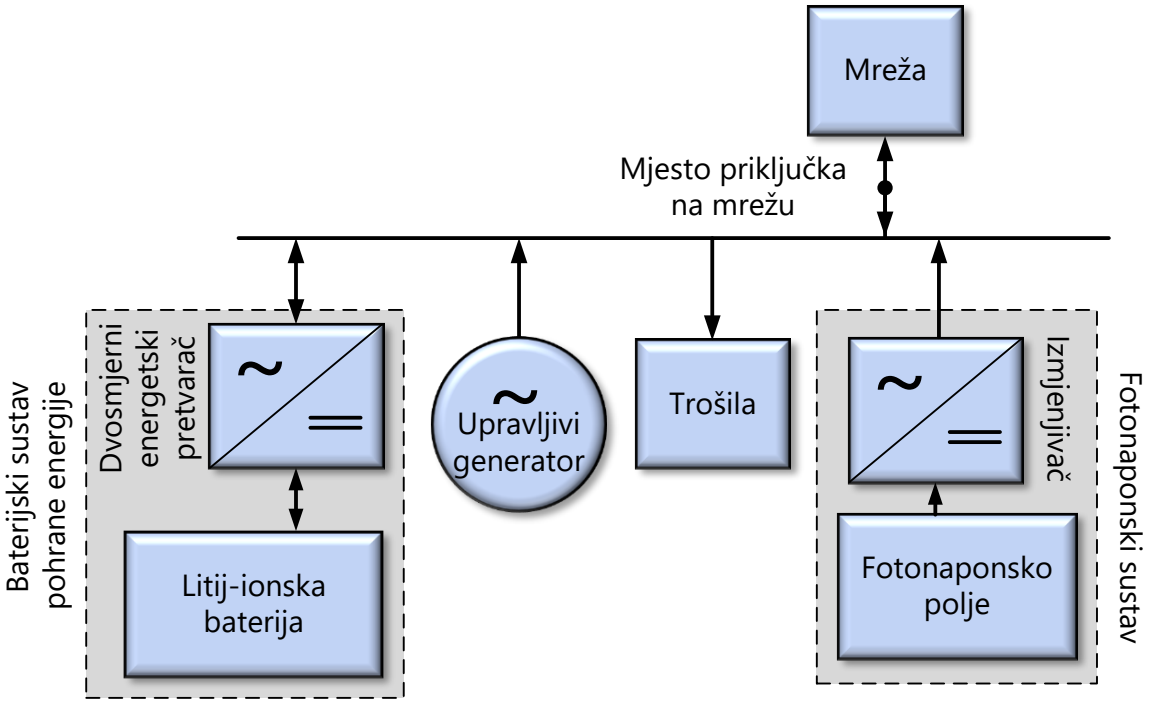

Slika 4.1: *Blokovska shema jednosabirničkog modela mikromreže*

4.1. Mreža (mjesto priključka mikromreže na nadređenu elektroenergetsku mrežu)

Model mreže odnosno mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu u optimizacijskom se problemu promatra kao element mikromreže s dvosmjernim tokom električne energije. Ovaj element predstavlja distribucijsku elektroenergetsku mrežu iz koje mikromreža može preuzimati (kupovati) električnu energiju ili je predavati (prodavati) u nju. Model također uključuje ograničenja koja se u stvarnosti susreću na mjestu razgraničenja krajnjih kupaca s vlastitom proizvodnjom (mikromreža) i operatora distribucijskog sustava.

Snaga razmjene električne energije između mikromreže i nadređene elektroenergetske mreže u svakom vremenskom trenutku optimizacije t ograničena je priključnom snagom u smjeru preuzimanja u izrazu 4-1) i priključnom snagom u smjeru predaje u izrazu 4-2:

$$P_t^{\text{grid in}} \leq P^{\text{grid in max}} \cdot s_t^{\text{grid status}} \quad \forall t \in T \tag{4-1}$$

$$P_t^{\text{grid out}} \leq P^{\text{grid out max}} \cdot (1 - s_t^{\text{grid status}}) \quad \forall t \in T \tag{4-2}$$

gdje su:

$P_t^{\text{grid in}}$ [kW] – snaga prilikom preuzimanja električne energije iz nadređene elektroenergetske mreže u vremenskom koraku t,

$P_t^{\text{grid out}}$ [kW] – snaga prilikom predaje električne energije u nadređenu elektroenergetsku mrežu u vremenskom koraku t,

$P^{\text{grid in max}}$ [kW] – priključna snaga u smjeru preuzimanja električne energije iz nadređene elektroenergetske mreže,

$P^{\text{grid out max}}$ [kW] – priključna snaga u smjeru predaje električne energije u nadređenu elektroenergetsku mrežu,

$s_t^{\text{grid status}}$ – binarna varijabla stanja mreže u vremenskom koraku t koja definira smjer razmjene električne energije između mikromreže i nadređene elektroenergetske mreže.

Izrazi 4-1 i 4-2 koriste binarnu varijablu stanja $s_t^{\text{grid status}}$ na način da sprječava preuzimanje i predaju električne energije u nadređenu elektroenergetsku mrežu u istom vremenskom koraku t. Ova varijabla poprima vrijednost 1 prilikom preuzimanja električne energije, a 0 prilikom predaje električne energije u nadređenu elektroenergetsku mrežu. Izrazi 4-1 i 4-2 predstavljaju generalizirani model mreže što znači da se može primijeniti na razne kombinacije postavki. Ako se u simulacijskim slučajevima modelira jedinična cijena u smjeru preuzimanja energije koja je viša od jedinične cijene u smjeru predaje energije u nadređenu elektroenergetsku mrežu, binarna varijabla $s_t^{\text{grid status}}$ se u izrazima 4-1 i 4-2 može izbaciti što smanjuje računalnu složenost optimizacijskog problema. Ako je jedinična cijena u smjeru predaje viša od jedinične cijene u smjeru preuzimanja energije ili ako su modelirane negativne jedinične cijene u smjeru preuzimanja energije, binarna varijabla će ispuniti svoju ulogu sprječavanja istovremenog preuzimanja i predaje električne energije u nadređenu elektroenergetsku mrežu.

Trošak preuzimanja i prihod od predaje električne energije iz nadređene elektroenergetske mreže definirani su izrazima 4-3 i 4-4 i uvršteni su kao članovi funkcije cilja optimizacijskog problema višeg sloja sustava upravljanja energijom mikromreže:

$$c_t^{\text{grid in}} = c_t^{\text{grid buy}} \cdot (P_t^{\text{grid in}} \cdot \Delta t) \quad \forall t \in T \tag{4-3}$$

$$c_t^{\text{grid out}} = c_t^{\text{grid sell}} \cdot (P_t^{\text{grid out}} \cdot \Delta t) \quad \forall t \in T \tag{4-4}$$

gdje su:

$c_t^{\text{grid in}}$ [kn] – trošak preuzimanja električne energije iz nadređene elektroenergetske mreže u vremenskom koraku t,

$c_t^{\text{grid out}}$ [kn] – prihod od predaje električne energije u nadređenu elektroenergetsku mrežu u vremenskom koraku t,

$c_t^{\text{grid buy}}$ [kn/kWh] – jedinična cijena električne energije u smjeru preuzimanja iz nadređene elektroenergetske mreže u vremenskom koraku t,

$c_t^{\text{grid sell}}$ [kn/kWh] – jedinična vrijednost električne energije u smjeru predaje u nadređenu elektroenergetsku mrežu u vremenskom koraku t,

Δt [h] – duljina vremenskog koraka.

Jedinične cijene električne energije u smjeru preuzimanja i predaje električne energije izražene su u novčanim jedinicama po jedinici energije (kWh).

Zadnji aspekt modeliran u matematičkom modelu mreže je trošak novoangažirane snage u obračunskom razdoblju uvršten kao član funkcije cilja optimizacijskog problema kojim se može postići smanjenje vršnog opterećenja mikromreže (engl. *Load peak shaving*). Trošak angažirane snage kod krajnjih kupaca obračunava se na kraju obračunskog razdoblja, najčešće na mjesečnoj razini, a ovisi o najvećoj angažiranoj snazi u tom razdoblju i jediničnom trošku izraženom po svakom kW snage preuzete električne energije iz nadređene elektroenergetske mreže uvećan za porez na dodanu vrijednost (PDV). Kako predložen sustav upravljanja energijom mikromreže planira kratkoročni pogon s horizontom planiranja od jednog do dva dana, trošak angažirane snage ne može se izravno uvrstiti u funkciju cilja jer ima puno duže vremensko razdoblje obračuna od vremenskog razdoblja za koji se računa dobit mikromreže, a koja predstavlja funkciju cilja ovog optimizacijskog problema. U suprotnom, ovaj bi trošak bi imao prevelik utjecaj na pogon mikromreže te se zbog toga u ovom modelu trošak angažirane snage računa pomoću novoangažirane snage u trenutnom horizontu planiranja *SH*. Novoangažirana snaga jednaka je razlici između najveće angažirane snage planirane u trenutnom horizontu planiranja *SH* i povijesne vrijednosti angažirane snage u tekućem obračunskom razdoblju m što je definirano izrazom 4-5:

$$\Delta P^{\text{grid peak}} = P^{\text{grid peak SH}} - P_m^{\text{grid peak}} \tag{4-5}$$

gdje su:

$\Delta P^{\text{grid peak}}$ [kW] – novoangažirana snaga u trenutnom horizontu planiranja *SH*,
$P^{\text{grid peak SH}}$ [kW] – najveća angažirana snaga planirana u trenutnom horizontu planiranja *SH*,
$P_m^{\text{grid peak}}$ [kW] – povijesna vrijednost najveće angažirane snage u tekućem obračunskom razdoblju m.

Prilikom određivanja novoangažirane snage u trenutnom horizontu planiranja *SH* mogu se susresti dva slučaja definirana izrazom 4-6.

$$\begin{aligned} &\text{Ako je: } P^{\text{grid peak SH}} \leq P_m^{\text{grid peak}} \quad \longrightarrow \quad \Delta P^{\text{grid peak}} = 0 \\ &\text{Ako je: } P^{\text{grid peak SH}} > P_m^{\text{grid peak}} \quad \longrightarrow \quad \Delta P^{\text{grid peak}} > 0 \end{aligned} \tag{4-6}$$

U slučaju da se postupak kratkoročnog planiranja pogona mikromreže provodi za prvi dan obračunskog razdoblja m, povijesna vrijednost najveće angažirane snage $P_m^{\text{grid peak}}$ nije unaprijed poznata što može rezultirati velikom novoangažiranom snagom u trenutnom horizontu planiranja *SH* i značajno utjecati na pogon mikromreže. Zbog ovog graničnog slučaja uvodi se pretpostavka za početak obračunskog razdoblja m u kojoj se za povijesnu vrijednost angažirane snage uzima vrijednost angažirane snage istog obračunskog razdoblja n u prošloj godini kao i promatrano obračunsko razdoblje m umanjena za koeficijent k koji poprima vrijednost između 0 i 1 definirano izrazom 4-7. Kako vrijednost najveće angažirane snage u istom obračunskom razdoblju n prošle godine i u trenutnom obračunskom razdoblju m nisu nužno iste zbog stohastičke prirode snage razmijene električne energije između mikromreže i nadređene elektroenergetske mreže, koja je rezultat razlike proizvodnje i potrošnje električne energije unutar mikromreže, u izrazu 4-7 se uvrštava koeficijent k kojim se želi postići smanjenje najveće angažirane snage u trenutnom obračunskom razdoblju m ispod razine najveće angažirane snage u obračunskom razdoblju n u prošloj godini.

$$P_m^{\text{grid peak}} = k \cdot P_n^{\text{grid peak}} \tag{4-7}$$

gdje su:

$P_n^{\text{grid peak}}$ [kW] – vrijednost angažirane snage u istom obračunskom razdoblju n prošle godine,
k – koeficijent umanjenja angažirane snage u istom obračunskom razdoblju n prošle godine.

Naposlijetku, trošak novoangažirane snage se određuje prema izrazu 4-8:

$$c^{\text{grid peak}} = c^{\text{peak price}} \cdot \Delta P^{\text{grid peak}} \cdot \left(1 + \frac{VAT}{100}\right) \tag{4-8}$$

gdje su:

$c^{\text{grid peak}}$ [kn] – trošak novoangažirane snage u horizontu planiranja SH,
$c^{\text{peak price}}$ [kn/kW] – jedinični trošak za angažiranu snagu.

4.2. Baterijski sustav pohrane energije

Kao i element mreže (mjesto priključka mikromreže na nadređenu elektroenergetsku mrežu), baterijski sustav pohrane energije (engl. *Battery energy storage system*) također je element mikromreže s dvosmjernim tokom električne energije gdje se tijekom punjenja ponaša kao trošilo, a tijekom pražnjenja kao izvor, pružajući dodatnu fleksibilnost u pogonu mikromreže. Svaki baterijski sustav pohrane energije sastoji se od pretvarača energetske elektronike i baterije, stoga se i matematički model u ovoj disertaciji sastoji od modela pretvarača i modela baterije koji čine model baterijskog sustava pohrane energije. Na slici 4.2 prikazana je blokovska shema baterijskog sustava pohrane energije na kojoj su veličine snage rastavljene na istosmjerne (DC) na strani baterije i izmjenične (AC) nakon dvosmjernog pretvarača energetske elektronike. U matematičkim izrazima koriste se indeksi *batt* za veličine na istosmjernoj (DC) strani (na strani baterije) i *ac* indeksi za veličine na izmjeničnoj (AC) strani dvosmjernog pretvarača energetske elektronike.

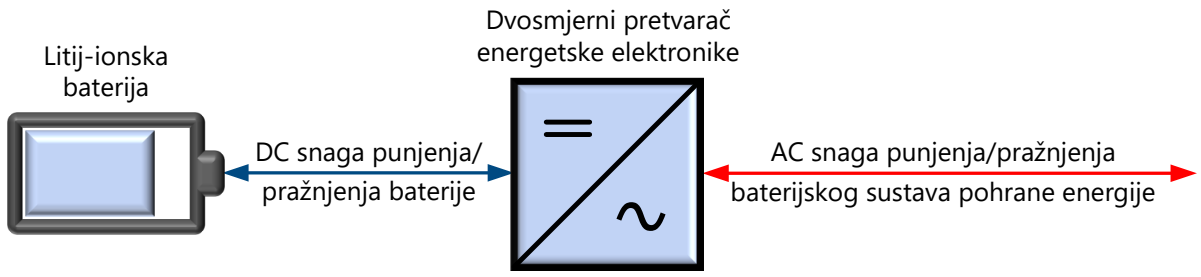

Slika 4.2: *Blokovska shema modela baterijskog sustava pohrane energije*

4.2.1. Dvosmjerni pretvarač energetske elektronike

Dvosmjerni pretvarač energetske elektronike (engl. *Bidirectional power converter unit*) je element s dvosmjernim tokovima energije čiji smjer energije ovisi o režimu rada (punjenje ili pražnjenje baterije). Snage punjenja i pražnjenja ovise o fizikalnim ograničenjima pretvarača

i u modelu su ograničene s obzirom na nazivnu snagu, kao što je vidljivo u izrazima 4-9 i 4-10.

$$P_{t,bess}^{\text{ch ac}} \leq P_{bess}^{\text{nom}} \cdot s_{t,bess}^{\text{BESS status}} \quad \forall t \in T, \forall bess \in BESS \tag{4-9}$$

$$P_{t,bess}^{\text{disch ac}} \leq P_{bess}^{\text{nom}} \cdot (1 - s_{t,bess}^{\text{BESS status}}) \quad \forall t \in T, \forall bess \in BESS \tag{4-10}$$

gdje su:

$P_{t,bess}^{\text{ch ac}}$ [kW] – snaga punjenja baterijskog sustava pohrane energije *bess* na izmjeničnoj strani u vremenskom koraku t,

$P_{t,bess}^{\text{disch ac}}$ [kW] – snaga pražnjenja baterijskog sustava pohrane energije *bess* na izmjeničnoj strani u vremenskom koraku t,

P_{bess}^{nom} [kW] – nazivna izmjenična snaga dvosmjernog pretvarača energetske elektronike baterijskog sustava pohrane energije *bess*,

$s_{t,bess}^{\text{BESS status}}$ – binarna varijabla stanja baterijskog sustava pohrane energije *bess* u vremenskom koraku t koja definira način rada (punjenje ili pražnjenje).

Kao i model elementa mreže, model baterijskog sustava pohrane energije u izrazima 4-9 i 4-10 koristi binarnu varijablu stanja $s_t^{\text{BESS status}}$ u svrhu sprječavanja punjenja i pražnjenja energije iz/u bateriju u istom vremenskom koraku t. Ova varijabla poprima vrijednost 1 prilikom punjenja, a 0 prilikom pražnjenja energije iz baterije. Izrazi 4-9 i 4-10 predstavljaju generalizirani model što znači da se može primijeniti na razne kombinacije postavki. Ako se u simulacijskim slučajevima koristi postavka da je učinkovitost dvosmjernog pretvarača energetske manja od 100 %, binarna varijabla $s_t^{\text{BESS status}}$ se ne mora koristiti što smanjuje računalnu složenost optimizacijskog problema.

Učinkovitost dvosmjernog pretvarača energetske elektronike nije konstantna, što većina literature na taj način i modelira, nego je nelinearna i ovisi o trenutnom opterećenju pretvarača. U ovom se modelu učinkovitost modelira pomoću nelinearne karakteristike, a primjer karakteristike prikazan je na slici 4.3. Snaga opterećenja pretvarača prikazana je u p.u. (*per unit*) vrijednostima koje predstavljaju relativan broj dobiven omjerom trenutnog opterećenja pretvarača i njegove nazivne snage. Na primjeru karakteristike prikazane na slici 4.3 vidljiva je niska učinkovitost pretvorbe energije pri malim opterećenjima pretvarača. Najveća učinkovitost javlja se prilikom opterećenja od 15 % nazivne snage pretvarača koja zatim opada s porastom opterećenja.

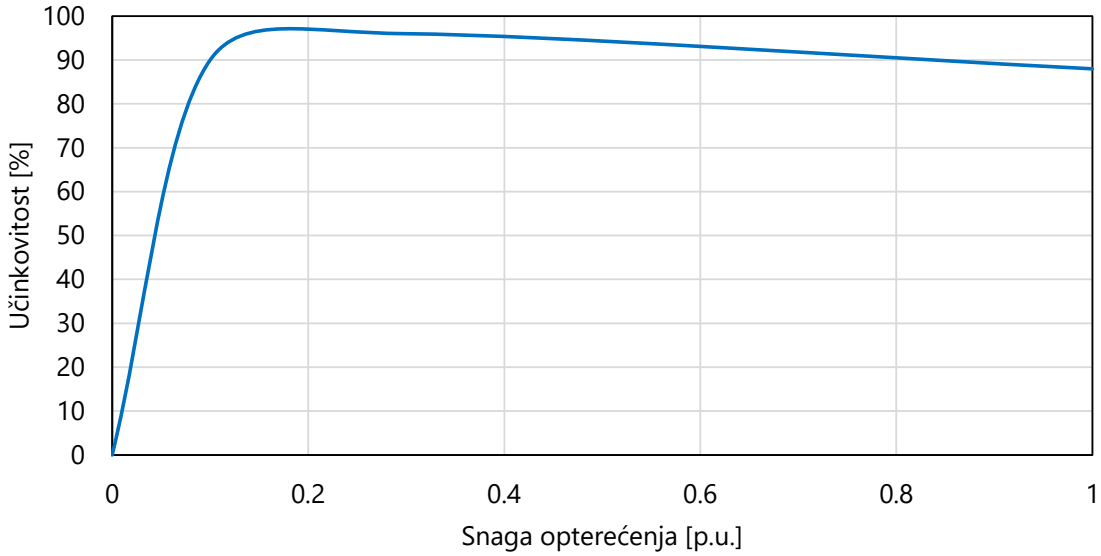

Slika 4.3: *Učinkovitost dvosmjernog pretvarača energetske elektronike ovisne o opterećenju*

Karakteristika učinkovitosti prikazana na slici 4.3 ne može se izravno uvrstiti u mješovito cjelobrojni linearni optimizacijski problem zbog svojstva nelinearnosti. Kako bi se uvrstila u linearni optimizacijski problem, u modelu se implementira tehnika linearizacije karakteristike pomoću više linearnih odsječaka (engl. *Piecewise linear approximation*). Kvaliteta (točnost) aproksimacije nelinearne karakteristike pomoću tehnike linearizacije ovisi o broju linearnih odsječaka. Povećanjem broja odsječaka povećava se točnost aproksimacije (i obratno), no u isto vrijeme se povećava i računalna složenost optimizacijskog problema, što zahtijeva kompromisno rješenje. Generalni zapis tehnike linearizacije funkcije pomoću više odsječaka vidljiv je u izrazu 4-11 uz grafički prikaz metode na slici 4.4 [91]:

$$
\begin{gathered}
L(f(x)) = \sum_{k=1}^{m} f(a_k) \cdot t_k \\
x = \sum_{k=1}^{m} a_k \cdot t_k \\
t_0 \leq y_0; \quad t_k \leq y_{k-1} + y_k; \quad \text{uz} \quad k = 1, 2, ..., m-1, t_m \leq y_{m-1} \\
\sum_{k=0}^{m-1} y_k = 1 \\
\sum_{k=0}^{m} t_k = 1 \quad \text{gdje su} \quad y_k \in \{0, 1\}, t_k \geq 0, k = 0, 1, ..., m-1
\end{gathered}
\tag{4-11}
$$

gdje su:

$f(x)$ – nelinearna funkcija varijable x koja se linearizira,
a_k – prijelomna točka k,
y_k – binarna varijabla lomne točke k.

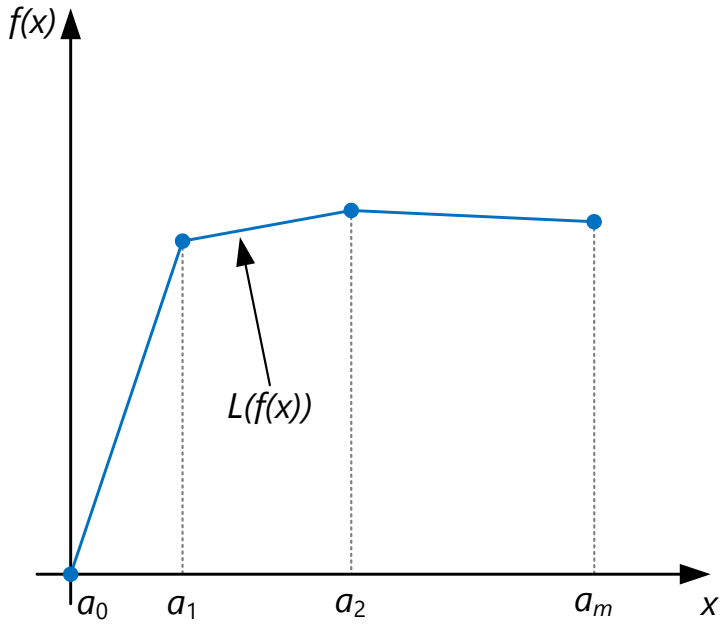

Slika 4.4: *Grafički prikaz linearizacije funkcije pomoću više linearnih odsječaka*

Primjer linearizacije nelinearne karakteristike prikazane na slici 4.3 pomoću tri linearna odsječka vidljiv je na slici 4.5.

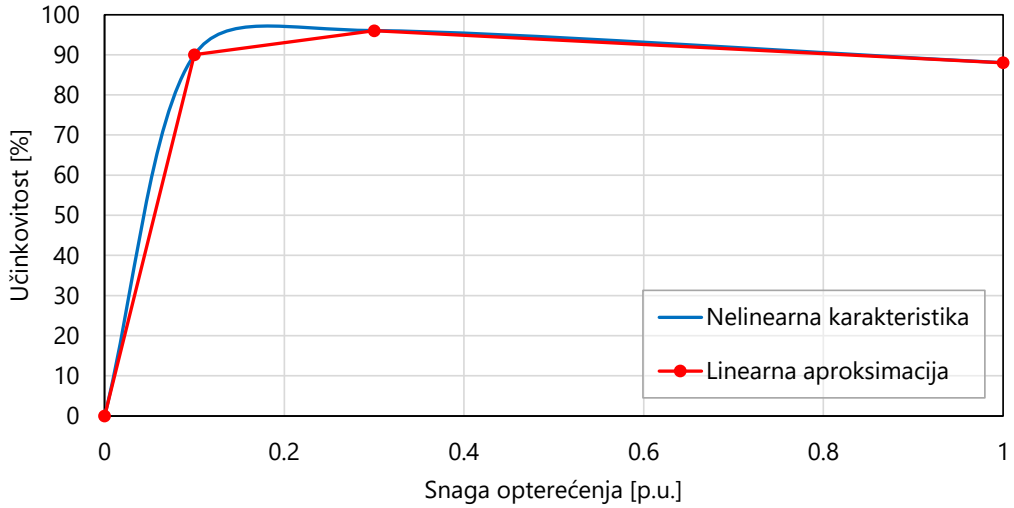

Slika 4.5: *Linearna aproksimacija učinkovitosti dvosmjernog pretvarača energetske elektronike ovisne o opterećenju pomoću više odsječaka*

Linearizirana krivulja učinkovitosti pretvarača koristi se prilikom izračuna snage punjenja ili pražnjenja kao što je prikazano u izrazima 4-12 i 4-13. Prema izrazu 4-12 snaga punjenja baterije na istosmjernoj strani $P_{t,bess}^{\text{ch batt}}$ jednaka je snazi punjenja na izmjeničnoj strani dvosmjernog pretvarača energetske elektronike $P_{t,bess}^{\text{ch ac}}$ umanjene za gubitke izražene pomoću učinkovitosti pretvorbe pretvarača η_{bess}^{PCU} koja ima funkcijsku ovisnost o toj snazi. Prema izrazu 4-13 snaga pražnjenja na izmjeničnoj strani baterijskog sustava pohrane energije $P_{t,bess}^{\text{disch ac}}$ jednaka je snazi pražnjenja baterije $P_{t,bess}^{\text{disch batt}}$ umanjene za gubitke izražene pomoću učinkovitosti pretvorbe pretvarača η_{bess}^{PCU} koja ima funkcijsku ovisnost o toj snazi.

$$P_{t,bess}^{\text{ch batt}} = P_{t,bess}^{\text{ch ac}} \cdot \eta_{bess}^{\text{PCU}}(P_{t,bess}^{\text{ch ac}}) \quad \forall t \in T, \forall bess \in BESS \tag{4-12}$$

$$P_{t,bess}^{\text{disch ac}} = P_{t,bess}^{\text{disch batt}} \cdot \eta_{bess}^{\text{PCU}}(P_{t,bess}^{\text{disch batt}}) \quad \forall t \in T, \forall bess \in BESS \tag{4-13}$$

gdje su:

$P_{t,bess}^{\text{ch batt}}$ [kW] – snaga punjenja baterije *bess* na istosmjernoj strani u vremenskom koraku t,

$P_{t,bess}^{\text{disch batt}}$ [kW] – snaga pražnjenja baterije *bess* na istosmjernoj strani u vremenskom koraku t,

η_{bess}^{PCU} [%] – učinkovitost pretvorbe energije dvosmjernog pretvarača energetske elektronike baterijskog sustava pohrane energije *bess*.

4.2.2. Model litij-ionske baterije

Model baterije definira ograničenja u radu s obzirom na stanje napunjenosti i s obzirom na snage punjenja i pražnjenja. Pojam stanja napunjenosti (engl. *State of Energy - SOE*) se u ovom modelu odnosi na pohranjenu energiju u bateriji izraženu u Wh (kWh) za razliku od većine istraživanja koja koriste pojam stanja napunjenosti (engl. *State of Charge - SOC*), koji po svojoj definiciji kvantificira stanje pohranjenog naboja izraženog u Ah. Korištenje pojma energetskog stanja napunjenosti u Wh je tehnički ispravnije jer se kod ovakvih studija, s razmjerno visokim energetskim kapacitetima baterijskih sustava pohrane energije, stanje napunjenosti baterije kvantificira pomoću izmijenjene energije (integriranjem snage u vremenu) umjesto razmijenjenog naboja (integriranje struje u vremenu). Za potrebe lakše intepretacije rezultata simulacija definirat će se poseban parametar koji stanje napunjenosti izražava u postocima.

Prvo ograničenje u radu baterije je ograničenje dozvoljene snage punjenja baterije. Kao što je već navedeno u pregledu literature, većina istraživanja ograničava dozvoljenu snagu

punjenja na iznos maksimalne dopuštene vrijednosti definirane tehničkim specifikacijama proizvođača baterije, bez obzira na trenutno stanje napunjenosti. Nekolicina istraživanja koristi točniju tehniku konstantne struje/konstantnog napona u funkcijskoj ovisnosti o trenutnom stanju napunjenosti, koja realnije modelira proces punjenja baterije. Kod metode konstantne struje/konstantnog napona, snaga punjenja je ograničena maksimalno dopuštenom snagom punjenja do određene razine (najčešće između 80 i 90 % stanja napunjenosti), a nakon toga snaga punjenja linearno opada s povećanjem stanja napunjenosti sve do nule. U ovom modelu se koristi energetski model punjenja baterije (engl. *Energy charging model*) prema [92] koji se pokazao kao najtočniji model punjenja litij-ionskih baterija za ovakvu vrstu studija. Usporedba tri različita modela ograničavanja snage punjenja u ovisnosti o trenutnom stanju napunjenosti baterije prikazana je na slici 4.6.

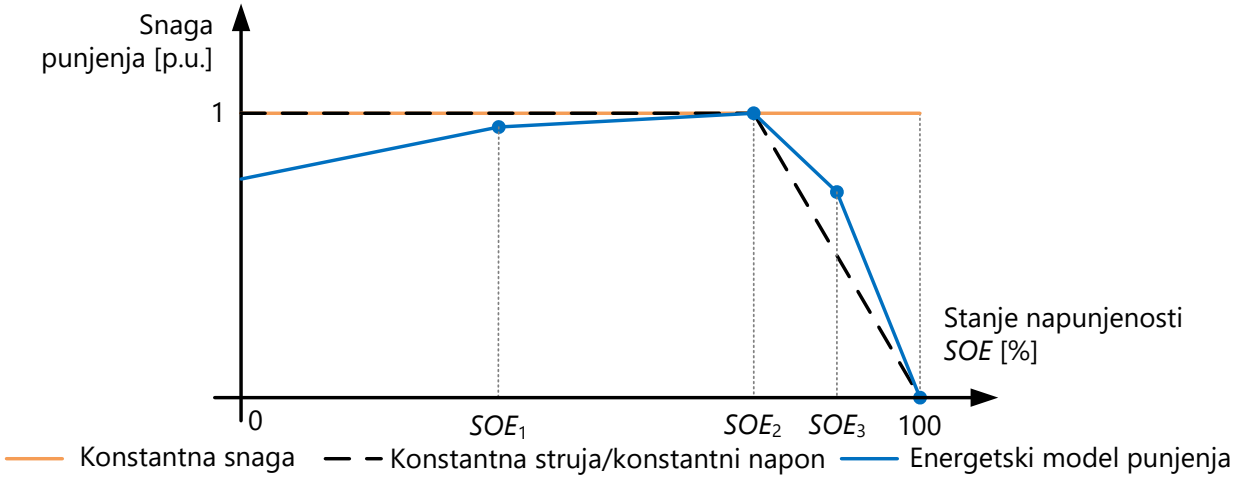

Slika 4.6: *Modeli punjenja litij-ionskih baterija*

Snaga punjenja kod energetskog modela punjenja ovisi o energiji koju baterija može apsorbirati ΔSOE, a koja ovisi o trenutnom stanju napunjenosti SOE. Nelinearna $\Delta SOE/SOE$ karakteristika dobivena snimanjem procesa punjenja litij-ionske baterije se linearizira tehnikom linearizacije pomoću više odsječaka. Analitički i grafički prikaz primjene energetskog modela punjenja dobivenog tehnikom linearizacije $\Delta SOE/SOE$ karakteristike pomoću više odsječaka te izraz za dozvoljenu snagu punjenja baterije je vidljiv u izrazu 4-14 i na slici 4.7 [92]:

$$
\begin{aligned}
SOE_t &= \sum_{j=1}^{J-1} SOE_{t,j} \\
SOE_{t,j} &\leq R_{j+1} - R_j \\
\Delta SOE_t &= F_1 + \sum_{j=1}^{J-1} \frac{F_{j+1} - F_j}{R_{j+1} - R_j} \cdot SOE_{t-1,j} \\
P_t^{\text{ch batt}} &\leq \frac{\Delta SOE_t}{\Delta t \cdot \eta^{\text{E}}}
\end{aligned}
\tag{4-14}
$$

gdje su:

SOE_t – stanje napunjenosti baterije u vremenskom koraku t,
J – broj segmenata linearizirane karakteristike,
$SOE_{t,j}$ – stanje napunjenosti segmenta j u vremenskom koraku t,
ΔSOE – energija koju baterija može apsorbirati tijekom procesa punjenja,
R – prijelomna točka na osi SOE,
F – prijelomna točka na osi ΔSOE,
η^{E} – energetska učinkovitost baterije.

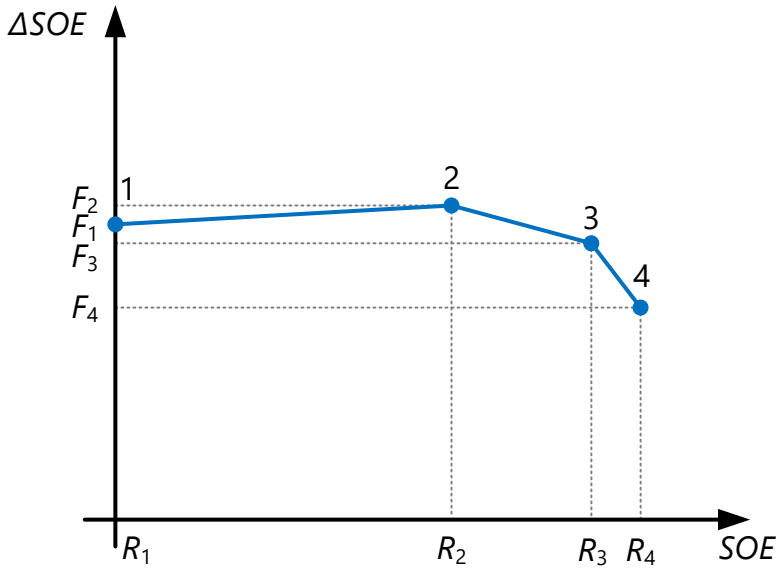

Slika 4.7: $\Delta SOE/SOE$ *karakteristika energetskog modela punjenja litij-ionskih baterija*

Tijekom procesa punjenja i pražnjenja baterija javljaju se gubici na unutarnjem otporu baterije. S povećanjem struja punjenja i pražnjenja povećavaju se i gubici što posljedično to utječe i na učinkovitost. Većina autora u istraživanjima koriste odvojene učinkovitosti prilikom procesa punjenja (engl. *Charging efficiency*) i pražnjenja (engl. *Discharging efficiency*) u kojima ne navode na koju učinkovitost se definirane veličine odnose. Općenito

se učinkovitosti baterija mogu podijeliti na tri vrste: učinkovitost vezana uz naboj (engl. *Coulombic efficiency*), učinkovitost vezana uz napon (engl. *Voltaic efficiency*) i učinkovitost vezana uz energiju (engl. *Energy efficiency*) - energetska učinkovitost. Učinkovitost vezana uz naboj definira se kao omjer naboja dobiven tijekom pražnjenja baterije i naboja uloženog tijekom procesa punjenja baterije. Učinkovitost vezana uz napon definira se kao omjer prosječnog napona prilikom pražnjenja i prosječnog napona prilikom punjenja baterije [92].

Energetska učinkovitost koja se koristi u ovom modelu i izrazu za dozvoljenu snagu punjenja baterije u 4-14 se definira kao omjer ispražnjenje energije iz baterije i energije uložene tijekom punjenja baterije za vrijeme cijelog ciklusa punjenja/pražnjenja. Ovo ujedno znači da će se u ovom modelu koristiti samo jedna učinkovitost koja uzima u obzir gubitke tijekom procesa punjenja i procesa pražnjenja zajedno (engl. *Round-trip efficiency*). Energetska učinkovitost je najniža od tri navedene te sadržava u sebi učinkovitost vezanu uz naboj i učinkovitost vezanu uz napon. Energetska učinkovitost određuje se prema izrazu 4-15 [92]:

$$\eta^{\mathrm{E}} = \frac{\int_0^{T\mathrm{disch}} P_{\mathrm{disch}}(t)\ \mathrm{dt}}{\int_0^{T\mathrm{ch}} P_{\mathrm{ch}}(t)\ \mathrm{dt}} \tag{4-15}$$

gdje su:

η^{E} – energetska učinkovitost baterije,
T^{disch} – vrijeme potrebno za potpuno pražnjenje baterije,
T^{ch} – vrijeme potrebno za potpuno punjenje baterije,
P_{disch} – snaga pražnjenja baterije,
P_{ch} – snaga punjenja baterije,
t – vrijeme.

Snaga pražnjenja baterije $P_{t,bess}^{\mathrm{disch\ batt}}$ baterijskog sustava pohrane energije *bess* u svakom vremenskom koraku t ograničena je maksimalno dozvoljenom snagom pražnjenja baterije $P_{bess}^{\mathrm{disch\ max\ batt}}$ [kW] koja ovisi tehničkim ograničenjima baterije, vidljivo u izrazu 4-16.

$$P_{t,bess}^{\mathrm{disch\ batt}} \leq P_{bess}^{\mathrm{disch\ max\ batt}} \quad \forall t \in T, \forall bess \in BESS \tag{4-16}$$

Stanje napunjenosti baterije (u kWh) u vremenskom koraku t ovisi o stanju napunjenosti baterije u prošlom vremenskom koraku $(t-1)$, energiji uloženoj tijekom punjenja i ispražnjenoj energije te energetskoj učinkovitosti prema izrazu 4-17:

$$SOE_{t,bess} = SOE_{t-1,bess} + (P_{t,bess}^{\text{ch batt}} \cdot \eta_{bess}^{\text{E}} \cdot \Delta t) - (P_{t,bess}^{\text{disch batt}} \cdot \Delta t) \quad \forall t \in T, \forall bess \in BESS \tag{4-17}$$

gdje su:

$SOE_{t,bess}$ [kWh] – stanje napunjenosti baterije baterijskog sustava pohrane energije *bess* u vremenskom koraku t,

$SOE_{t-1,bess}$ [kWh] – stanje napunjenosti baterije baterijskog sustava pohrane energije *bess* u prošlom vremenskom koraku $(t-1)$,

$P_{t,bess}^{\text{ch batt}}$ [kW] – snaga punjenja baterije baterijskog sustava pohrane energije *bess* u vremenskom koraku t,

$P_{t,bess}^{\text{disch batt}}$ [kW] – snaga pražnjenja baterije baterijskog sustava pohrane energije *bess* u vremenskom koraku t,

η_{bess}^{E} [%] – energetska učinkovitost baterije baterijskog sustava pohrane energije *bess*,

Δt [h] – duljina vremenskog koraka.

Osim stanja napunjenosti baterije izražene u iznosu spremljene energije $SOE_{t,bess}$ [kWh], radi lakše interpretacije veličina i rezultata simulacija, definira se stanje napunjenosti baterije izražene postotno u odnosu na nazivni energetski kapacitet baterije prema izrazu 4-18:

$$SOE_{t,bess}^{\%} = \frac{SOE_{t,bess}}{E_{bess}^{\text{cap}}} \tag{4-18}$$

gdje su:

$SOE_{t,bess}^{\%}$ [%] – stanje napunjenosti baterije baterijskog sustava pohrane energije *bess* u vremenskom koraku t,

E_{bess}^{cap} [kWh] – energetski kapacitet baterije baterijskog sustava pohrane energije *bess*

Stanje napunjenosti baterije se ograničava s minimalnom i maksimalnom razinom izraženom u postocima, definirano izrazima 4-19 i 4-20:

$$SOE_{t,bess}^{\%} \geq SOE_{bess}^{\min} \quad \forall t \in T, \forall bess \in BESS \tag{4-19}$$

$$SOE_{t,bess}^{\%} \leq SOE_{bess}^{\max} \quad \forall t \in T, \forall bess \in BESS \tag{4-20}$$

gdje su:

$SOE_{bess}^{\min}$ [%] – minimalno stanje napunjenosti baterije baterijskog sustava pohrane energije *bess*,

$SOE_{bess}^{\max}$ [%] – maksimalno stanje napunjenosti baterije baterijskog sustava pohrane energije *bess*.

Stanje napunjenosti baterije na početku horizonta planiranja (vremenski korak 0) ovisi o početnom stanju sustava IS_i odnosno iteraciji optimizacije i, vidljivo na slici 3.1. Na početku optimizacijskog postupka u prvoj iteraciji ($i = 0$) početno stanje napunjenosti definira se pomoću parametra SOE_{bess}^{init} [%] prema izrazu 4-21. Stanje napunjenosti u svim višim iteracijama ($i = 1, 2, 3, ...$) ovisi o stanju napunjenosti na kraju prošle iteracije. Ovo je jedno od obilježja strategije pomičnog horizonta s korektivnim djelovanjem koja koristi spojne varijable (engl. *Linking variables*). Spojne varijable povezuju pojedine slojeve sustava upravljanja energijom i pojedine iteracije. Jedna od spojnih varijabli je i stanje napunjenosti baterije čiji se iznos u zadnjem vremenskom koraku prošle iteracije prosljeđuje kao početno stanje za sljedeću iteraciju. Točnije, ako se promotri blokovska shema na slici 3.2, stanje napunjenosti u zadnjem vremenskom koraku horizonta upravljanja $CH_{i\text{-}1}$ nižeg sloja sustava upravljanja energijom mikromreže u prošloj iteraciji $(i-1)$ se prosljeđuje višem sloju sustava upravljanja energijom mikromreže kao početno stanje napunjenosti baterije za sljedeću iteraciju i.

$$SOE_{0,bess}^{\%} = SOE_{bess}^{\text{init}} \quad \forall bess \in BESS \tag{4-21}$$

Stanje napunjenosti baterije na kraju horizonta planiranja nije eksplicitno navedeno kao što to većina istraživanja definira. U tu svrhu se u ovom modelu koristi poseban član funkcije cilja koji valorizira pohranjenu energiju u bateriji baterijskog sustava pohrane energije detaljnije opisan u poglavlju 4.2.4.

4.2.3. Degradacija baterijskog sustava pohrane energije

Degradacija baterije uzrokovana raznim faktorima stresa u literaturi se najčešće svrstavaju pod cikličko i kalendarsko starenje. Uvrštavajući dodatne (virtualne) troškove u funkciji cilja želi se spriječiti učestalo punjenje i pražnjenje te visoka stanja ispražnjenosti što produžuje životni vijek baterije koje imaju razmjerno visoke investicijske troškove. Ukupni dodatni (virtualni) trošak degradacije u ovom modelu definira se prema izrazu 4-22 kao zbroj troška kalendarskog i troška cikličkog starenja.

$$c_{t,bess}^{\text{BESS deg}} = c_{t,bess}^{\text{cal ageing}} + c_{t,bess}^{\text{cyc ageing}} \quad \forall t \in T, \forall bess \in BESS \tag{4-22}$$

gdje su:

$c_{t,bess}^{\text{BESS deg}}$ [kn] – ukupni trošak degradacije baterije baterijskog sustava pohrane energije *bess* u vremenskom koraku t,

$c_{t,bess}^{\text{cal ageing}}$ [kn] – trošak kalendarskog starenja baterije baterijskog sustava pohrane energije *bess* u vremenskom koraku t,

$c_{t,bess}^{\text{cyc ageing}}$ [kn] – trošak cikličkog starenja baterije baterijskog sustava pohrane energije *bess* u vremenskom koraku t.

Glavni uzroci kalendarskog starenja baterije su temperatura i stanje napunjenosti baterije [93]. Dodatni (virtualni) trošak kalendarskog starenja u ovoj disertaciji modelira se prema metodologiji predstavljenoj u [94]. Ova metodologija koristi normaliziranu nelinearnu karakteristiku faktora stresa kalendarskog starenja baterije kao funkciju stanja napunjenosti baterije (SOE). Porastom stanja napunjenosti raste i faktor stresa. Kako bi se nelinearna karakteristika mogla uvrstiti u linearni optimizacijski problem, ona se aproksimira pomoću pravca. Nelinearna i linearna karakteristika faktora stresa kalendarskog starenja baterije prikazane su na slici 4.8. Stanje napunjenosti od 50 % predstavlja nominalnu razinu faktora stresa kalendarskog starenja.

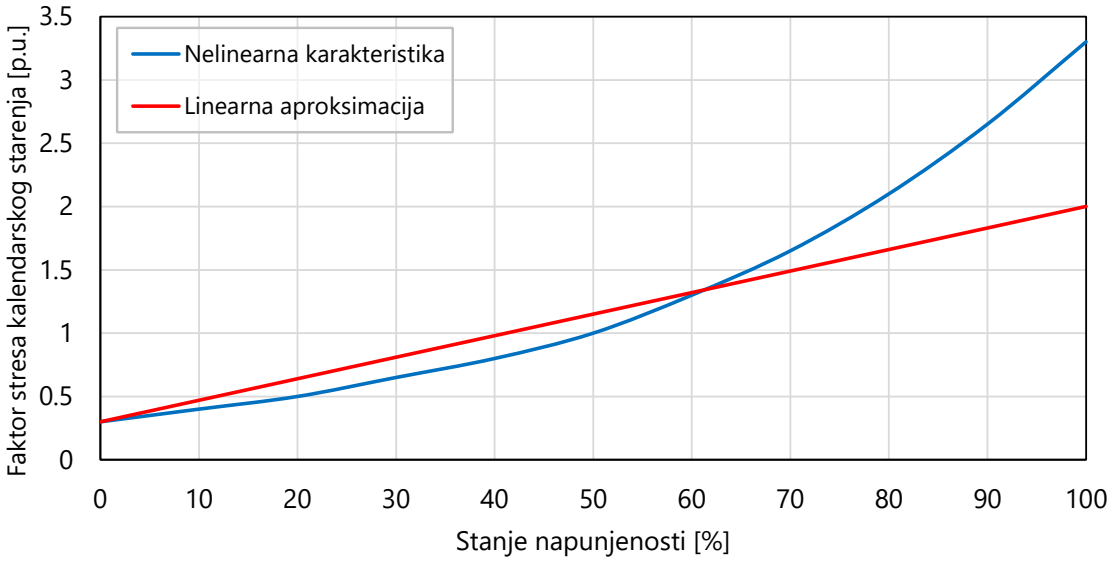

Slika 4.8: *Karakteristika faktora stresa kalendarskog starenja baterije*

Linearizacijom krivulje na slici 4.8 dobije se jednadžba pravca s oblikom u izrazu 4-23. Jednadžba pravca ima koeficijente $k_0^{\text{cal}} = 0.3$, a $k^{\text{cal}} = 1.7$ [94]. Utjecaj temperature prema ovoj metodologiji neizravno je uključen kroz navedene koeficijente.

$$S_{SOE}^{\text{cal, lin}} = k_0^{\text{cal}} + k^{\text{cal}} \cdot SOE \tag{4-23}$$

gdje su:

$S_{SOE}^{\text{cal, lin}}$ – faktor stresa kalendarskog starenja,
$k_0^{\text{cal}}, k^{\text{cal}}$ – koeficijenti jednadžbe pravca,
SOE – stanje napunjenosti baterije.

Naposlijetku, prema metodologiji [94] dodatni (virtualni) trošak kalendarskog starenja definira se prema izrazu 4-24:

$$c_{t,bess}^{\text{cal ageing}} = \frac{c_{bess}^{\text{replace cost}}}{T_{bess}^{\text{lifetime}}} \cdot \left(k_0^{\text{cal}} + k^{\text{cal}} \cdot \left(\frac{SOE_{t,bess} + SOE_{t-1,bess}}{2} \right) \right) \quad \forall t \in T, \forall bess \in BESS \tag{4-24}$$

gdje su:

$c_{bess}^{\text{replace cost}}$ [kn] – trošak zamjene (investicijski trošak) baterijskog sustava pohrane energije *bess*,
$T_{bess}^{\text{lifetime}}$ – životni vijek baterijskog sutava pohrane energije *bess* izražen u broju vremenskih koraka optimizacijskog problema.

U izrazu 4-24 treba zamijetiti da se uzima prosječna vrijednost stanja napunjenosti baterije u trenutnom i prethodnom vremenskom koraku. Prema obliku izraza također se može zaključiti da trošak kalendarskog starenja uvijek postoji, bez obzira koristi li se baterijski sustav pohrane (način punjenja ili pražnjenja) ili je u stanju mirovanja. Također, porastom stanja napunjenosti raste i dodatni (virtualni) trošak kalendarskog starenja čime se operatora mikromreže na taj način potiče da, u slučaju nekorištenja (u stanju mirovanja) baterijskog sustava pohrane energije, drži stanje napunjenosti na što nižoj razini. Razina stanja napunjenosti baterije će na kraju ovisiti o odnosima s ostalim troškovima odnosno prihodima.

Trošak zamjene baterijskog sustava pohrane energije u izrazu 4-24 predstavlja investicijski trošak izražen u novčanim jedinicama po kWh energetskog kapaciteta baterijskog sustava pohrane energije. Kako se baterijski sustavi pohrane energije instaliraju u različitim iznosima instalirane snage dvosmjernih pretvarača energetske elektronike i s različitim energetskim kapacitetima baterije, njihov investicijski trošak ovisi o cijenama pojedinih stavki. U ovom modelu koristi se metodologija NREL-a (engl. *National Renewable Energy Laboratory*) predstavljena u [95] koja ukupni investicijski trošak (trošak zamjene) baterijskog sustava pohrane energije definira kao zbroj investicijskog troška komponenti snage (dvosmjerni pretvarač energetske elektronike) izražen po kW instalirane snage i investicijskog troška energetskih komponenti (energetski kapacitet baterije) izražen po kWh instaliranog kapaciteta prema izrazu 4-25. Kako je prvi investicijski trošak istražen po pojedinom kW

instalirane snage, a drugi po kWh instaliranog energetskog kapaciteta, da bi ukupni investicijski trošak bio izražen po kWh energetskog kapaciteta baterijskog sustava, koristi se transformacija uvrštavanjem trajanja korištenja. Trajanje korištenja predstavlja vrijeme potrebno za pražnjenje potpuno napunjene baterije pri nazivnoj izmjeničnoj snazi dvosmjernog pretvarača energetske elektronike prema izrazu 4-26.

$$c_{bess}^{\text{replace cost}} = \left(c^{\text{price kWh}} + \frac{c^{\text{price kW}}}{T_{bess}^{\text{duration}}} \right) \cdot E_{bess}^{\text{cap}} \quad \forall bess \in BESS \tag{4-25}$$

$$T_{bess}^{\text{duration}} = \frac{E_{bess}^{\text{cap}}}{P_{bess}^{\text{nom}}} \quad \forall bess \in BESS \tag{4-26}$$

gdje su:

$c^{\text{price kWh}}$ [kn/kWh] – investicijski trošak baterije izražen po kWh energetskog kapaciteta,
$c^{\text{price kW}}$ [kn/kW] – investicijski trošak dvosmjernog pretvarača energetske elektronike izražen po kW instalirane snage,
$T_{bess}^{\text{duration}}$ [h] – trajanje korištenja baterijskog sustava pohrane energije *bess*,
E_{bess}^{cap} [kWh] – energetski kapacitet baterije baterijskog sustava pohrane energije *bess*,
P_{bess}^{nom} [kW] – nazivna izmjenična snaga dvosmjernog pretvarača energetske elektronike baterijskog sustava pohrane energije *bess*.

Osim kalendarskog starenja, u modelu baterijskog sustava pohrane energije u obzir se uzima i cikličko starenje baterijskog sustava pohrane energije. Cikličko starenje se modelira prema metodologiji predstavljenoj u [70] u obliku dodatnog (virtualnog) troška. Iako su glavni uzroci cikličkog starenja dubina ciklusa pražnjenja baterije, prekomjerno punjenje i pražnjenje baterije, struje punjenja i pražnjenja (faktor C) te prosječno stanje napunjenosti, predstavljena metodologija uzima samo dubinu ciklusa pražnjenja baterije kao glavni uzrok cikličkog starenja. Prekomjerno punjenje i pražnjenje baterije redovito se ograničava s minimalnim i maksimalnim razinama stanja napunjenosti baterije što je i u ovom modelu ograničeno izrazima 4-19 i 4-20. Visoke struje pražnjenja i punjenja ubrzavaju degradaciju baterije, no kako se ovdje radi o modeliraju baterijskog sustava pohrane energije velikog energetskog kapaciteta (duljina trajanja korištenja je veća od 15 minuta), ovaj utjecaj se prema [96] može zanemariti. Prosječno stanje napunjenosti svakog ciklusa ima blago nelinearan i slab utjecaj na cikličko starenje baterije, stoga se prema [70] ovaj utjecaj također može zanemariti.

Oblik profila stanja napunjenosti jednog ciklusa ovisi o energiji punjenja/pražnjenja baterije tijekom pogona baterijskog sustava pohrane energije. Kako bi se modelirao utjecaj

dubine ciklusa pražnjenja na cikličko starenje baterije, svaki ciklus se mora kvantificirati i odrediti njegovu dubinu pražnjenja (engl. *Depth of Discharge - DOD*) jer ciklus s većom dubinom pražnjenja uzrokuje veću degradaciju od ciklusa s manjom dubinom pražnjenja. Kod problema ovakve prirode u praksi se koristi algoritam padanja kiše (engl. *rainflow*). Ovaj algoritam najčešće se koristi u strojarstvu za analizu zamora materijala uslijed cikličkog naprezanja. Problem ovog algoritma je što nema analitički matematički zapis i stoga ga je teško uvrstiti u optimizacijski problem. Kako bi se uvrstio u optimizacijski problem, metodologija predstavljena u [70] i korištena u ovom modelu, koristi linearizaciju nelinearne funkcije gubitka životnog vijeka baterije pomoću više odsječaka kako bi se odredio granični trošak cikličkog starenja svakog ciklusa s određenom dubinom pražnjenja. Metodologija pretpostavlja da samo pražnjenje baterije uzrokuje cikličko starenje.

Dodatni (virtualni) trošak cikličkog starenja prema metodologiji [70], a korišten i u [97] opisat će se na jednom primjeru. Uzmimo primjer ciklusa baterije s pražnjenjem od početnog stanja napunjenosti SOE^{start} do krajnjeg stanja napunjenosti SOE^{end} i punjenjem do početnog stanja napunjenosti SOE^{start}. Dubina ciklusa pražnjenja δ definira se kao razlika stanja napunjenosti baterije u odnosu na energetski kapacitet baterije E^{cap} prema izrazu 4-27:

$$\delta = \frac{SOE^{\text{start}} - SOE^{\text{end}}}{E^{\text{cap}}} = \frac{\Delta SOE}{E^{\text{cap}}} \tag{4-27}$$

Ako se baterija od trenutka $t-1$ do trenutka t isprazni od dubine pražnjenja ciklusa δ_{t-1} do δ_t, razlika dubine ciklusa pražnjenja $\Delta\delta_t$ jednaka je ispražnjenoj energiji izraženoj u odnosu na energetski kapacitet baterije E^{cap} prema izrazu 4-28:

$$\Delta\delta_t = \delta_t - \delta_{t-1} = \frac{P_t^{\text{disch batt}} \cdot \Delta t}{E^{\text{cap}}} \tag{4-28}$$

Granični trošak cikličkog starenja određuje se pomoću derivacije efekta starenja ciklusa $\Phi(\delta)$ s dubinom pražnjenja δ po snazi pražnjenja $P^{\text{disch batt}}$ prema izrazu 4-29 [70]:

$$\frac{\partial \Phi(\delta)}{\partial P^{\text{disch batt}}} = \frac{\mathrm{d}\Phi(\Delta\delta)}{\mathrm{d}\delta} \cdot \frac{\partial \delta}{\partial P^{\text{disch batt}}} = \frac{\Delta t}{E^{\text{cap}}} \cdot \frac{\mathrm{d}\Phi(\Delta\delta)}{\mathrm{d}\delta} \tag{4-29}$$

Granični trošak cikličkog starenja baterijskog sustava pohrane energije ovisi o funkciji gubitka životnog vijeka baterije u ovisnosti o dubini pražnjenja ciklusa i trošku zamjene (investicijskom trošku). Linearnom aproksimacijom nelinearne funkcije gubitka životnog vijeka pomoću J odsječaka u rasponu od 0 % do 100 % dubine pražnjenja ciklusa dobiva se funkcija troška $c(\delta_t)$ u izrazu 4-30 [70]:

$$c(\delta_t) = \begin{cases} c_1 & \longrightarrow \delta_t \in \left[0, \frac{1}{J}\right] \\ \vdots & \\ c_j & \longrightarrow \delta_t \in \left[\frac{j-1}{J}, \frac{j}{J}\right] \\ \vdots & \\ c_J & \longrightarrow \delta_t \in \left[\frac{J-1}{J}, 1\right] \end{cases} \tag{4-30}$$

Trošak cikličke degradacije svakog odsječka j baterijskog sustava pohrane energije *bess* definira se prema izrazu 4-31 [70]:

$$c_{bess,j} = c_{bess}^{\text{replace cost}} \cdot J \cdot \left[\Phi\left(\frac{j}{J}\right) - \Phi \cdot \left(\frac{j-1}{J}\right)\right] \tag{4-31}$$

Dodatni (virtualni) trošak cikličkog starenja određuje se kao zbroj troškova po svim segmentima (odsječcima) j prema izrazu 4-32 [70]:

$$c_{t,bess}^{\text{cyc ageing}} = \sum_{j=1}^{J} c_{bess,j} \cdot P_{t,bess,j}^{\text{disch batt}} \cdot \Delta t \quad \forall t \in T, \forall bess \in BESS \tag{4-32}$$

U izrazima 4-28, 4-29 i 4-32 ne koristi se energetska učinkovitost η^{E} jer se ona pridružuje samo kod procesa punjenja, a sadržava gubitke energije i u procesu punjenja i u procesu pražnjenja (učinkovitost cijelog ciklusa), vidljivo u izrazu 4-15.

Nelinearna funkcija gubitka životnog vijeka baterije uslijed ciklusa s određenim pražnjenjem ovisi o tipu, tehnologiji baterije i njenim radnim uvjetima. Autori korištene metodologije u [70] koriste matematički oblik funkcije prikazan u 4-33 preuzet iz [98], a koja je dobivena eksperimentalnim mjerenjima na NiMnCo 18650 litij-ionskim baterijskim člancima predstavljenim u [99]. Kao što je vidljivo u 4-33 funkcija gubitka životnog vijeka $\Phi(\delta)$ ima približno kvadratnu ovisnost o dubini pražnjenja ciklusa δ.

$$\Phi(\delta) = (5.24 \cdot 10^{-4}) \cdot \delta^{2.03} \tag{4-33}$$

Grafički prikaz nelinearne funkcije gubitka životnog vijeka uslijed cikličkog starenja iz izraza 4-33 i njene linearne aproksimacije s 4 odsječka (segmenta) vidljiv je na slici 4.9.

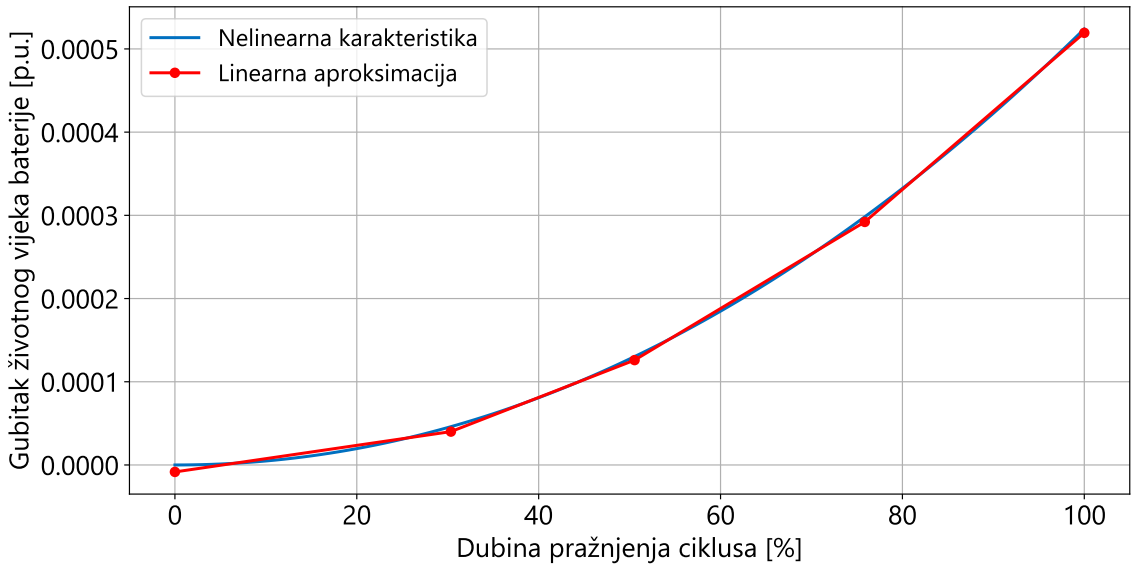

Slika 4.9: *Karakteristika gubitka životnog vijeka baterije uslijed cikličkog starenja*

4.2.4. Vrijednost pohranjene energije baterijskog sustava pohrane energije

Većina autora u literaturi eksplicitno definira stanje napunjenosti baterije na kraju horizonta planiranja. Ovo ne mora nužno donijeti optimalan pogon mikromreže, posebice u slučajevima kada se ne planira korištenje baterijskog sustava pohrane energije u sljedećem razdoblju. U ovom modelu uvrštava se dodatni (virtualni) prihod kao član funkcije cilja koji valorizira pohranjenu energiju u baterijskom sustavu pohrane energije na kraju horizonta planiranja (vremenski korak T) kojim se regulira stanje napunjenosti baterije. Dodatni (virtualni) prihod izračunava novčanu vrijednost pohranjene energije koju bi operator/vlasnik mikromreže ostvario kada bi se ona potpuno ispraznila te se pritom ne bi morala preuzeti energija iz nadređene elektroenergetske mreže (od opskrbljivača), vidljivo u izrazu 4-34. Izraz uzima u obzir prosječnu jediničnu cijenu prilikom preuzimanja energije iz mreže za J vremenskih koraka u budućnosti. Broj J predstavlja vrijeme potrebno da se baterijski sustav pohrane energije *bess* isprazni pri nazivnoj izmjeničnoj snazi dvosmjernog pretvarača energetske elektronike (trajanje korištenja definirano izrazom 4-26) izraženo kao broj vremenskih koraka optimizacijskog problema t.

$$c_{bess}^{\text{BESS VOSE}} = SOE_{T,bess} \cdot \frac{1}{J_{bess}} \cdot \sum_{j=1}^{J_{bess}} c_j^{\text{grid buy}} \quad \forall bess \in BESS \tag{4-34}$$

gdje su:

$c_{bess}^{\text{BESS VOSE}}$ [kn] – vrijednost pohranjene energije baterijskog sustava pohrane energije *bess*,

$SOE_{t,bess}$ [kWh] – stanje napunjenosti baterijskog sustava pohrane energije *bess* u vremenskom koraku t,

$c_t^{\text{grid buy}}$ [kn/kWh] – jedinična cijena prilikom preuzimanja energije iz mreže u vremenskom koraku t.

4.3. Fotonaponski sustav

Model fotonaponskog sustava predstavlja izvor električne energije u mikromreži i sastoji se od modela fotonaponskog polja i izmjenjivača prikazan na slici 4.10. Model fotonaponskog sustava za ulazne parametre uzima profile fizikalnih veličina o kojima ovisi profil proizvodnje električne energije, a to su snaga sunčevog zračenja i temperatura okoliša.

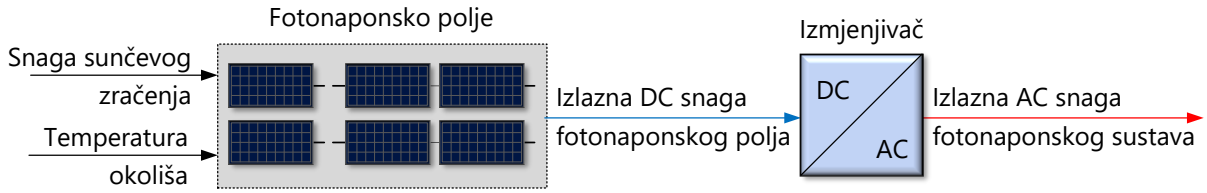

Slika 4.10: *Blokovska shema modela baterijskog sustava pohrane energije*

Izlazna istosmjerna (DC) snaga fotonaponskog polja prema IEC 61724-2 normi [100] ovisi o snazi sunčevog zračenja i temperaturi ćelija fotonaponskih modula, a računa se prema izrazu 4-35. Temperatura ćelija ovisi o karakteristikama fotonaponskih modula od kojih je fotonaponsko polje načinjeno, temperaturi okoliša i snazi sunčevog zračenja prema izrazu 4-36 [101].

$$P_{t,pv}^{\text{DC}} = P_{pv}^{\text{array STC}} \cdot \frac{G_t}{G^{\text{STC}}} \cdot \left(1 - \frac{\gamma_{pv}}{100} \cdot \left(\vartheta_{t,pv}^{\text{mod}} - \vartheta^{\text{STC}}\right)\right) \quad \forall t \in T, \forall pv \in PV \tag{4-35}$$

$$\vartheta_{t,pv}^{\text{mod}} = \vartheta_t^{\text{amb}} + \frac{NOCT_{pv} - 20}{800} \cdot G_t \quad \forall t \in T, \forall pv \in PV \tag{4-36}$$

gdje su:

$P_{t,pv}^{\mathrm{DC}}$ [kW] – izlazna istosmjerna snaga fotonaponskog polja fotonaponskog sustava pv u vremenskom koraku t,
$P_{pv}^{\text{array STC}}$ [kW] – snaga fotonaponskog polja fotonaponskog sustava pv pri standardnim testnim uvjetima,
G_t [kW/m^2] – snaga sunčevog zračenja u vremenskom koraku t,
G^{STC} [kW/m^2] – snaga sunčevog zračenja pri standardnim testnim uvjetima koja iznosi 1 kW/m^2,
γ_{pv} [%/°C] – temperaturni koeficijent snage fotonaponskih modula fotonaponskog sustava pv,
$\vartheta_{t,pv}^{\mathrm{mod}}$ [°C] – temperatura ćelija fotonaponskog sustava pv u vremenskom koraku t,
ϑ^{STC} [°C] – temperatura ćelija pri standardnim testnim uvjetima koja iznosi 25 °C,
$\vartheta_t^{\mathrm{amb}}$ [°C] – temperatura okoliša u vremenskom koraku t,
$NOCT_{pv}$ [°C] – nominalna radna temperatura ćelija fotonaponskog sustava pv.

Izlazna izmjenična (AC) snaga fotonaponskog sustava ovisi o izlaznoj istosmjernoj (DC) snazi fotonaponskog polja i učinkovitosti pretvorbe izmjenjivača prema izrazu 4-37. Kao i kod baterijskog sustava pohrane energije, učinkovitost izmjenjivača fotonaponskog sustava ovisi o trenutnom opterećenju pretvarača. Ovdje je korištena ista tehnika linearizacije nelinearne karakteristike učinkovitosti pomoću više odsječaka korištena u poglavlju 4.2.1 s analitičkim zapisom u izrazu 4-11 i grafičkim prikazom na slici 4.3. U određenim slučajevima izlazna istosmjerna (DC) snaga fotonaponskog polja može biti veća od nazivne izmjenične snage izmjenjivača fotonaponskog sustava što se ograničava izrazom 4-38.

$$P_{t,pv}^{\mathrm{AC}} = P_{t,pv}^{\mathrm{DC}} \cdot \eta_{pv}^{\mathrm{inv}}\left(P_{t,pv}^{\mathrm{DC}}\right) \quad \forall t \in T, \forall pv \tag{4-37}$$

$$P_{t,pv}^{\mathrm{AC}} \leq P_{pv}^{\text{inv nom}} \quad \forall t \in T, \forall pv \tag{4-38}$$

gdje su:

$P_{t,pv}^{\mathrm{AC}}$ [kW] – izlazna izmjenična (AC) snaga fotonaponskog sustava pv u vremenskom koraku t,
η_{pv}^{inv} [%] – učinkovitost izmjenjivača fotonaponskog sustava pv,
$P_{pv}^{\text{inv nom}}$ [kW] – nazivna izmjenična snaga izmjenjivača fotonaponskog sustava pv.

4.4. Upravljivi generator

Upravljivi generator (engl. *Dispatchable generator*) kao dodatni izvor električne energije u mikromreži osigurava veću pouzdanost napajanja, posebice u izoliranom (otočnom) pogonu mikromreže. Model upravljivog generatora ima oblik otprije poznatih optimizacijskih problema angažiranja agregata (engl. *Unit commitment*) i ekonomične raspodjele opterećenja (engl. *Economic dispatching*), a cilj mu je omogućiti integraciju različitih tipova distribuiranih izvora energije u obliku mikroturbina i generatora s motorom na unutarnje izgaranje (benzinski, dizelski, plinski). Model omogućuje modeliranje jedinica s različitim instaliranim snagama, ovisno o veličini mikromreže, gdje se kod manjih jedinica određena ograničenja mogu zanemariti.

Izlazna snaga upravljivog generatora ograničena je minimalnom i maksimalnom snagom prema izrazu 4-39 [39]. Ograničenje minimalne snage predstavlja tehnički minimum proizvodnje koji se kod manjih jedinica može zanemariti, ovisno o instaliranoj snazi jedinice koja se modelira. U izrazu 4-39 koristi se binarna varijabla angažiranja upravljivog generatora $u_{t,dg}^{\text{DG state}}$ koja poprima vrijednost 1 kada je generator u pogonu, a 0 kada je izvan pogona. Maksimalna izlazna snaga najčešće predstavlja instaliranu snagu generatora.

$$P_{dg}^{\text{DG min}} \cdot u_{t,dg}^{\text{DG state}} \leq P_{t,dg}^{\text{DG}} \leq P_{dg}^{\text{DG max}} \cdot u_{t,dg}^{\text{DG state}} \quad \forall t \in T, \forall dg \in DG \tag{4-39}$$

gdje su:

$P_{dg}^{\text{DG min}}$ [kW] – minimalna izlazna snaga upravljivog generatora dg,
$P_{dg}^{\text{DG max}}$ [kW] – maksimalna izlazna snaga upravljivog generatora dg,
$P_{t,dg}^{\text{DG}}$ [kW] – izlazna snaga upravljivog generatora dg u vremenskom koraku t,
$u_{t,dg}^{\text{DG state}}$ – binarna varijabla angažiranja upravljivog generatora dg u vremenskom koraku t.

Određene proizvodne jedinice imaju ograničenje promjene izlazne snage (proizvodnje) između vremenskih koraka (intervala) što se također modelira u ovom modelu. Promjena iznosa proizvodnje upravljivog generatora na gore (povećanje) ograničava se izrazom 4-40, a na dolje (smanjenje) izrazom 4-41 [102]. Ovo se ograničenje kod manjih jedinica može zanemariti, a ovisi i o duljini vremenskog koraka optimizacijskog problema.

$$P_{t,dg}^{\text{DG}} - P_{t-1,dg}^{\text{DG}} \leq P_{dg}^{\text{DG RU}} \quad \forall t \in T, \forall dg \in DG \tag{4-40}$$

$$P_{t-1,dg}^{\text{DG}} - P_{t,dg}^{\text{DG}} \leq P_{dg}^{\text{DG RD}} \quad \forall t \in T, \forall dg \in DG \tag{4-41}$$

gdje su:

$P_{dg}^{\text{DG RU}}$ [kW] – maksimalna promjena izlazne snage pri regulaciji na gore,
$P_{dg}^{\text{DG RD}}$ [kW] – maksimalna promjena izlazne snage pri regulaciji na dolje.

Određene jedinice upravljivog generatora imaju ograničenje minimalnog vremena proizvodnje nakon što su pokrenute, odnosno minimalno vrijeme prestanka proizvodnje nakon što su zaustavljene, prikazano izrazima 4-42 i 4-43. Kako bi se ovo ograničenje integriralo, definiraju se dvije nove binarne varijable $s_{t,dg}^{\text{DG start}}$ i $s_{t,dg}^{\text{DG stop}}$ s ograničenjima definiranim u izrazima 4-44 i 4-45 [102]. Ova ograničenja se također mogu zanemariti kod jedinica s malom instaliranom snagom.

$$\sum_{t}^{t+T_{dg}^{\text{DG on}}-1} u_{t,dg}^{\text{DG state}} \geq T_{dg}^{\text{DG on}} \cdot s_{t,dg}^{\text{DG start}} \quad \forall t \in T, \forall dg \in DG \tag{4-42}$$

$$\sum_{t}^{t+T_{dg}^{\text{DG off}}-1} \left(1 - u_{t,dg}^{\text{DG state}}\right) \geq T_{dg}^{\text{DG off}} \cdot s_{t,dg}^{\text{DG stop}} \quad \forall t \in T, \forall dg \in DG \tag{4-43}$$

$$u_{t,dg}^{\text{DG state}} - u_{t-1,dg}^{\text{DG state}} = s_{t,dg}^{\text{DG start}} - s_{t,dg}^{\text{DG stop}} \quad \forall t \in T, \forall dg \in DG \tag{4-44}$$

$$s_{t,dg}^{\text{DG start}} + s_{t,dg}^{\text{DG stop}} \leq 1 \quad \forall t \in T, \forall dg \in DG \tag{4-45}$$

gdje su:

$s_{t,dg}^{\text{DG start}}$ – binarna varijabla pokretanja upravljivog generatora dg u vremenskom koraku t,
$s_{t,dg}^{\text{DG stop}}$ – binarna varijabla zaustavljanja upravljivog generatora dg u vremenskom koraku t,
$T_{dg}^{\text{DG on}}$ – minimalno vrijeme proizvodnje upravljivog generatora t izraženo u broju vremenskih koraka optimizacijskog problema,
$T_{dg}^{\text{DG off}}$ – minimalno vrijeme prestanka proizvodnje upravljivog generatora t izraženo u broju vremenskih koraka optimizacijskog problema.

Ukupni trošak rada upravljivog generatora definira se kao zbroj troška pokretanja i troška za gorivo izrazom 4-46:

$$c_{t,dg}^{\text{DG cost}} = c_{t,dg}^{\text{DG startup}} + c_{t,dg}^{\text{DG fuel}} \quad \forall t \in T, \forall dg \in DG \tag{4-46}$$

gdje su:

$c_{t,dg}^{\text{DG cost}}$ [kn] – ukupni trošak rada upravljivog generatora dg u vremenskom koraku t,
$c_{t,dg}^{\text{DG startup}}$ [kn] – trošak pokretanja upravljivog generatora dg u vremenskom koraku t,
$c_{t,dg}^{\text{DG fuel}}$ [kn] – trošak za gorivo upravljivog generatora dg u vremenskom koraku t.

Neke proizvodne jedinice zahtijevaju potrošnju goriva prije pokretanja proizvodnje električne energije, stoga se u ovom modelu modelira i trošak pokretanja upravljivog generatora $c_{t,dg}^{\text{DG startup}}$ definiran izrazom 4-47 koji ovisi o jediničnom trošku pokretanja $c_{dg}^{\text{DG start}}$ [kn] i stanju binarne varijable pokretanja $s_{t,dg}^{\text{DG start}}$. Ovaj trošak se kod manjih proizvodnih jedinica može zanemariti.

$$c_{t,dg}^{\text{DG startup}} = c_{dg}^{\text{DG start}} \cdot s_{t,dg}^{\text{DG start}} \quad \forall t \in T, \forall dg \in DG \tag{4-47}$$

Trošak goriva upravljivog generatora ovisi o izlaznoj snazi te se ta ovisnost u literaturi redovito predstavlja kvadratnom funkcijom prikazanom u izrazu 4-48 [103]. Da bi se funkcija troška goriva uvrstila u mješovito cjelobrojni linearni optimizacijski problem, koristi se tehnika linearizacije pomoću više odsječaka čiji je analitički zapis prikazan u izrazu 4-49 [104], a grafički prikaz vidljiv je na slici 4.11.

$$c^{\text{DG fuel}}(P) = a \cdot P^2 + b \cdot P \tag{4-48}$$

$$\begin{aligned} c^{\text{DG fuel}}(P) &= \sum_{k=1}^{K} c_k \cdot \lambda_k \\ P &= \sum_{k=1}^{K} \Delta_k \cdot \lambda_k \\ \sum_{k=1}^{K} \lambda_k &= u^{\text{DG state}} \\ \lambda_k &\geq 0, \ k = 1, ..., K \end{aligned} \tag{4-49}$$

gdje su:

$c^{\text{DG fuel}}$ – trošak goriva upravljivog generatora,
a, b – koeficijenti kvadratne funkcije troška goriva,
c_k – prijelomna točka k na osi $c^{\text{DG fuel}}$,
λ_k – segment k izlazne snage upravljivog generatora,
Δ_k – prijelomna točka k na osi P.

Treba zamijetiti da analitički zapis u izraz 4-49 predstavlja inačicu u kojoj funkcija troška

goriva ne kreće iz ishodišta. U slučaju da krivulja kreće iz ishodišta, u analitičkom zapisu u izrazu 4-49 predzadnji red se mora zamijeniti s izrazom 4-50 [104].

$$\sum_{k=1}^{K} \lambda_k = 1 \tag{4-50}$$

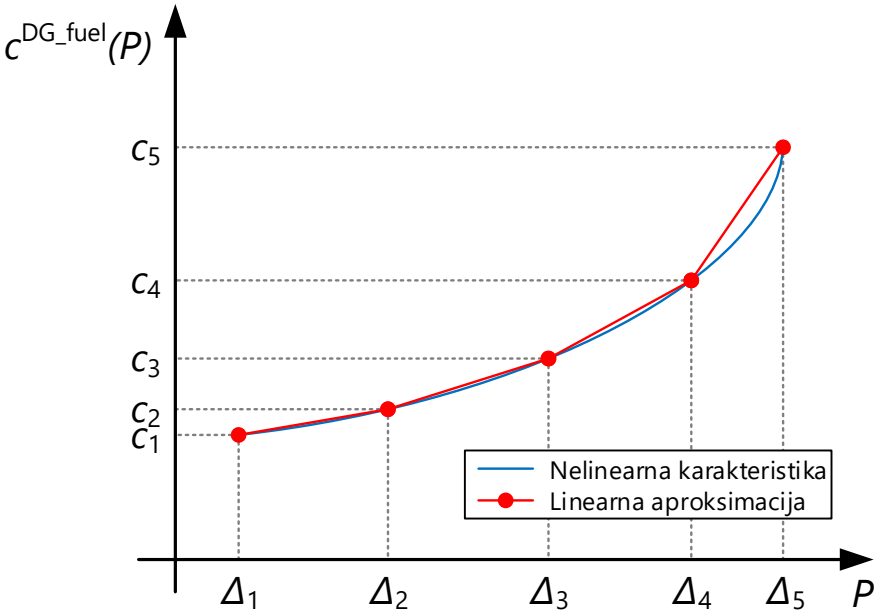

Slika 4.11: *Linearizacija funkcije troška goriva upravljivog generatora*

4.5. Trošila električne energije

Trošila električne energije mikromreže dijele se u dvije osnovne skupine, neupravljiva (kritična) trošila koja moraju imati neprestanu opskrbu električnom energijom i upravljiva trošila (engl. *Controllable loads*) čijom se potrošnjom električne energije može upravljati. Upravljiva trošila omogućuju rasterećenje (engl. *Load shedding*) čime se povećava fleksibilnost pogona mikromreže posebice kada je u izoliranom (otočnom) pogonu u odnosu na nadređenu elektroenergetsku mrežu. Modelirane su tri vrste upravljivih trošila s obzirom na njihove karakteristike i stupanj upravljivosti:

- Statički upravljiva trošila (engl. *Static-controllable loads*);
- Dinamički upravljiva trošila (engl. *Dynamic-controllable loads*);
- Vremenski odgodiva trošila (engl. *Time-shiftable loads*).

4.5.1. Statički upravljiva trošila

Model statički upravljivih trošila pokušava obuhvatiti trošila s više jedinica kao što su veliki klimatizacijski sustavi i grijači prostora. Potrošnjom električne energije upravlja se u diskretnim koracima ovisno o broju jedinica sustava trošila definirano parametrom n. Snaga potrošnje električne energije statički upravljivog trošila ovisi o planiranoj snazi potrošnje i stanju varijable $s_{t,l}^{\text{stat}}$ prema izrazu 4-51. Varijabla $s_{t,l}^{\text{stat}}$ poprima vrijednost između 0 i 1 u n diskretnih koraka. Grafički prikaz upravljanja potrošnjom rada statički upravljivog trošila s 3 jedinice vidljiv je na slici 4.12.

$$P_{t,l}^{\text{stat}} = \left(1 - s_{t,l}^{\text{stat}}\right) \cdot P_{t,l}^{\text{stat bsln}} \quad \forall t \in T, \forall l \in L^{\text{stat}}, s_{t,l}^{\text{stat}} \in [0, n_1, n_2, n_3, ..., 1] \tag{4-51}$$

gdje su:

$P_{t,l}^{\text{stat}}$ [kW] – snaga potrošnje statički upravljivog trošila l u vremenskom koraku t,
$P_{t,l}^{\text{stat bsln}}$ [kW] – planirana snaga potrošnje statički upravljivog trošila l u vremenskom koraku t,
$s_{t,l}^{\text{stat}}$ – varijabla upravljanja statički upravljivog trošila l u vremenskom koraku t.

Učestalo upravljanje potrošnjom narušava komfor korisnika. Kako bi se to spriječilo, definira se dodatni (virtualni) trošak definiran u izrazu 4-52 koji ovisi o jediničnom trošku upravljanja. Ovaj model trošila omogućuje smanjenje potrošnje (rasterećenje) mikromreže što ima veliku ulogu u izoliranom (otočnom) pogonu mikromreže u slučaju manjka proizvedene električne energije.

$$c_{t,l}^{\text{stat}} = c_l^{\text{stat}} \cdot s_{t,l}^{\text{stat}} \quad \forall t \in T, \forall l \in L^{\text{stat}} \tag{4-52}$$

gdje su:

$c_{t,l}^{\text{stat}}$ [kn] – trošak upravljanja potrošnjom statički upravljivog trošila l u vremenskom koraku t,
c_l^{stat} [kn] – jedinični trošak upravljanja potrošnjom statički upravljivog trošila l.

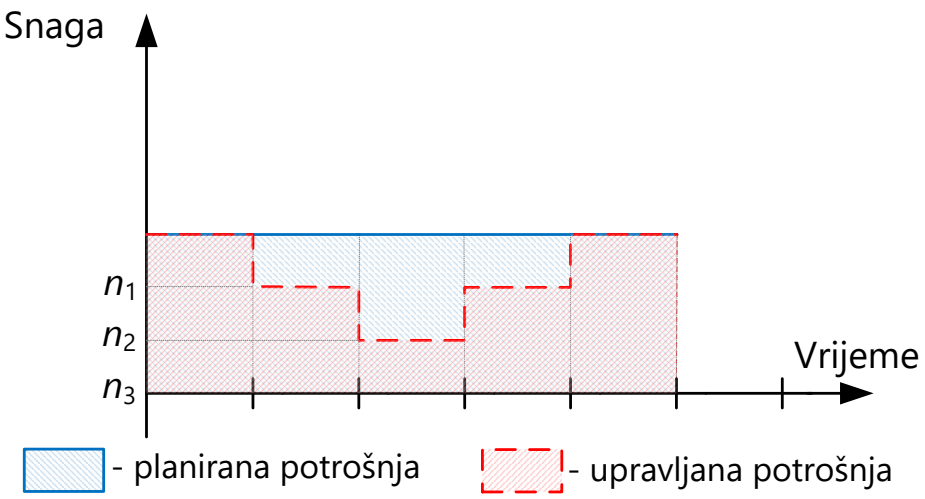

Slika 4.12: *Upravljanje potrošnjom statički upravljivog trošila*

4.5.2. Dinamički upravljiva trošila

Modelom dinamički upravljivih trošila pokušavaju se obuhvatiti elektronički upravljana trošila kao što su upravljiva (prigušiva) rasvjeta (engl. *Dimmable lighting*) i klimatizacijske jedinice s izmjenjivačem (engl. *Inverter-based air conditioning units*). Snaga potrošnje električne energije dinamički upravljivog trošila ovisi o planiranoj snazi potrošnje i stanju kontinuirane varijable $s_{t,l}^{\text{dyn}}$ prema izrazu 4-53. Varijabla $s_{t,l}^{\text{dyn}}$ može poprimiti bilo koju vrijednost između 0 i 1 gdje 0 znači neupravljanje potrošnjom, a 1 potpuno rasterećenje. Grafički prikaz upravljanja potrošnjom rada dinamički upravljivog trošila vidljiv je na slici 4.13.

$$P_{t,l}^{\text{dyn}} = \left(1 - s_{t,l}^{\text{dyn}}\right) \cdot P_{t,l}^{\text{dyn bsln}} \quad \forall t \in T, \forall l \in L^{\text{dyn}}, s_{t,l}^{\text{dyn}} \in [0,1] \tag{4-53}$$

gdje su:

$P_{t,l}^{\text{dyn}}$ [kW] – snaga potrošnje dinamički upravljivog trošila l u vremenskom koraku t,
$P_{t,l}^{\text{dyn bsln}}$ [kW] – planirana snaga potrošnje dinamički upravljivog trošila l u vremenskom koraku t,
$s_{t,l}^{\text{dyn}}$ – varijabla upravljanja dinamički upravljivog trošila l u vremenskom koraku t.

Kako bi se spriječilo učestalo upravljanje potrošnjom definira se dodatni (virtualni) trošak koji ovisi o jediničnom trošku upravljanja kao i kod statički upravljivog trošila, prikazano izrazom 4-54. Ovaj model također omogućuje smanjenje potrošnje (rasterećenje) mikromreže što ima veliku ulogu u izoliranom (otočnom) pogonu mikromreže.

$$c_{t,l}^{\text{dyn}} = c_l^{\text{dyn}} \cdot s_{t,l}^{\text{dyn}} \quad \forall t \in T, \forall l \in L^{\text{dyn}} \tag{4-54}$$

gdje su:

$c_{t,l}^{\text{dyn}}$ [kn] – trošak upravljanja potrošnjom dinamički upravljivog trošila l u vremenskom koraku t,

c_{l}^{dyn} [kn] – jedinični trošak upravljanja potrošnjom dinamički upravljivog trošila l.

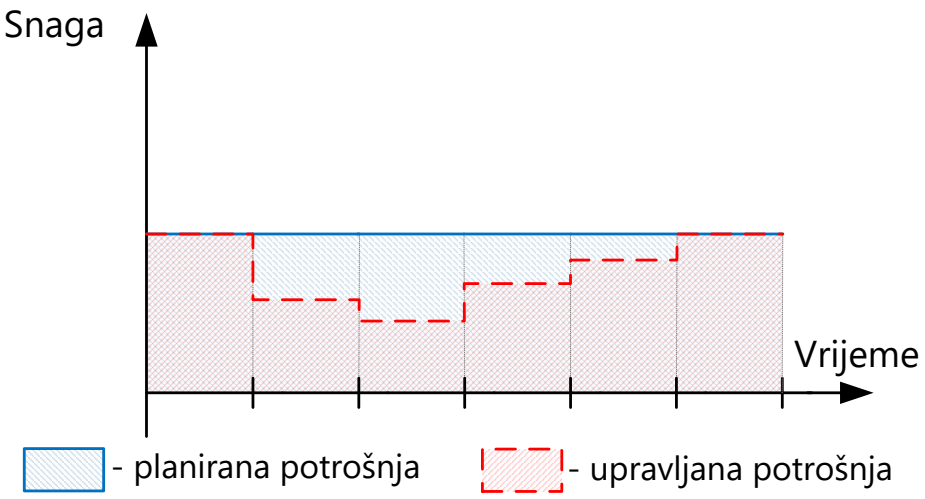

Slika 4.13: *Upravljanje potrošnjom dinamički upravljivog trošila*

4.5.3. Vremenski odgodivo trošilo

Model vremenski odgodivog trošila omogućuje odgodu potrošnje (ciklusa) u drugo vremensko razdoblje pružajući dodatnu fleksibilnost u pogonu mikromreže. Tipovi trošila koji se obuhvaćaju ovim modelom su pametni kućanski uređaji (engl. *Smart appliances*), toplinske pumpe, grijači i električna vozila. U razvijenom modelu korisnik definira vremenski trenutak (korak) priključenja trošila u mikromrežu t_l^{start} što za električno vozilo znači priključenje na punionicu ili uključenje pametnog uređaja u stanje mirovanja. Algoritam određuje vrijeme (vremenski korak) kraja planiranog profila potrošnje bez odgode t_l^{stop} na osnovu vremena t_l^{start}. Korisnik definira vrijeme (vremenski korak) do kojeg ciklus trošila mora biti gotov t_l^{end} što za električno vozilo znači napunjena baterija, a za pametni uređaj završetak ciklusa rada. Optimizacijski problem određuje trajanje odgode početka odnosno vremenski korak početka ciklusa. Model pretpostavlja da se planirani profil potrošnje ne može mijenjati (upravljati razinom potrošnje) i jednom pokrenut ciklus ne može se zaustaviti (odgoditi). Analitički zapis algoritma slijedi u nastavku, dok je grafički prikaz principa rada vidljiv na slici 4.14.

Algoritam izračunava maksimalni broj scenarija odgode $n_l^{\text{shft max}}$ prema izrazu 4-55:

$$n_l^{\text{shft max}} = t_l^{\text{end}} - t_l^{\text{stop}} \quad \forall l \in L^{\text{shft}} \tag{4-55}$$

Za svaki mogući scenarij odgode p algoritam generira odgovarajući profil potrošnje prema izrazu 4-56:

$$P_{t,l,p}^{\text{load shft}} = P_{(t+p),l}^{\text{load shft bsline}} \quad \forall t \in T, \forall l \in L^{\text{shft}}, \forall p \in \left[0, n_l^{\text{shft max}}\right] \tag{4-56}$$

gdje su:

$P_{t,l,p}^{\text{load shft}}$ [kW] – snaga potrošnje vremenski odgodivog trošila l u vremenskom koraku t za scenarij odgode p,

$P_{t,l}^{\text{load shft bsline}}$ [kW] – planirana snaga potrošnje vremenski odgodivog trošila l u vremenskom koraku t.

Svakom scenariju odgode dodjeljuje se binarna varijabla $s_{l,p}^{\text{load shft}}$ za koju vrijedi ograničenje prikazano u izrazu 4-57, a koje definira da samo jedan scenarij odgode može biti optimalan:

$$\sum_{p=0}^{n_l^{\text{shft max}}} s_{l,p}^{\text{load shft}} = 1 \quad \forall l \in L^{\text{shft}}, \forall p \in \left[0, n_l^{\text{shft max}}\right] \tag{4-57}$$

Naposlijetku, snaga potrošnje $P_{t,l}^{\text{load shft}}$ [kW] vremenski odgodivog trošila l u vremenskom koraku t definira se prema izrazu 4-58:

$$P_{t,l}^{\text{load shft}} = P_{t,l,p}^{\text{load shft}} \cdot s_{l,p}^{\text{load shft}} \quad \forall t \in T, \forall l \in L^{\text{shft}}, \forall p \in \left[0, n_l^{\text{shft max}}\right] \tag{4-58}$$

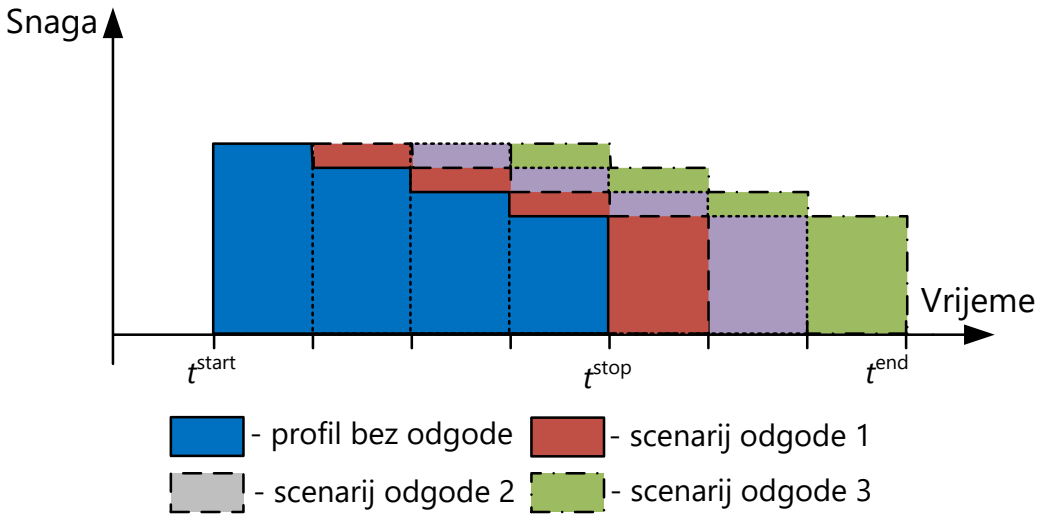

Slika 4.14: *Princip rada vremenski odgodivog trošila*

4.6. Funkcija cilja

Cilj optimizacijskog problema višeg sloja sustava upravljanja energijom je maksimizirati dobit mikromreže u promatranom horizontu planiranja. Prikaz funkcije cilja vidljiv je u

izrazu 4-59. Funkcija cilja realizirana je kao funkcija s više članova gdje svaki član predstavlja prihod ili trošak odvojene u dvije skupine: pogonske prihode/troškove i dodatne (virtualne) prihode/troškove.

$$\text{maksimiziraj} \quad \Bigg[\overbrace{\sum_{t=1}^{T}\left(c_t^{\text{grid out}} - c_t^{\text{grid in}}\right) - c^{\text{grid peak}} - \sum_{t=1}^{T}\left(\sum_{dg=1}^{DG} c_{t,dg}^{\text{DG cost}}\right)}^{\text{pogonski prihodi/troškovi}} \underbrace{- \sum_{t=1}^{T}\left(\sum_{bess=1}^{BESS} c_{t,bess}^{\text{BESS deg}}\right) + c_{bess}^{\text{BESS VOSE}} - \sum_{t=1}^{T}\left(\sum_{l=1}^{L^{\text{stat}}} c_{t,l}^{\text{stat}} + \sum_{l=1}^{L^{\text{dyn}}} c_{t,l}^{\text{dyn}}\right)}_{\text{dodatni (virtualni) prihodi/troškovi}} \Bigg] \tag{4-59}$$

gdje su:

- $c_t^{\text{grid out}}$ [kn] – prihod od predaje električne energije u nadređenu elektroenergetsku mrežu u vremenskom koraku t,
- $c_t^{\text{grid in}}$ [kn] – trošak preuzimanja električne energije iz nadređene elektroenergetske mreže u vremenskom koraku t,
- $c^{\text{grid peak}}$ [kn] – trošak novoangažirane snage u promatranom horizontu planiranja,
- $c_{t,dg}^{\text{DG cost}}$ [kn] – ukupni trošak rada upravljivog generatora dg u vremenskom koraku t,
- $c_{t,bess}^{\text{BESS deg}}$ [kn] – ukupni trošak degradacije baterije baterijskog sustava pohrane energije $bess$ u vremenskom koraku t,
- $c_{bess}^{\text{BESS VOSE}}$ [kn] – vrijednost pohranjene energije baterijskog sustava pohrane energije $bess$ na kraju promatranog horizonta planiranja,
- $c_{t,l}^{\text{stat}}$ [kn] – trošak upravljanja potrošnjom statički upravljivog trošila l u vremenskom koraku t,
- $c_{t,l}^{\text{dyn}}$ [kn] – trošak upravljanja potrošnjom dinamički upravljivog trošila l u vremenskom koraku t.

Osim funkcije cilja i definiranih ograničenja u modelima elemenata mikromreže, za optimizacijski problem još se definira i ograničenje bilance tokova snaga prema izrazu 4-60. U bilanci tokova snaga vrijedi da proizvedena električna energije u svakom vremenskom koraku t mora biti jednaka potrošenoj električnoj energiji.

$$\overbrace{P_t^{\text{grid in}} + \sum_{bess=1}^{BESS} P_{t,bess}^{\text{disch ac}} + \sum_{pv=1}^{PV} P_{t,pv}^{\text{AC}} + \sum_{dg=1}^{DG} P_{t,bess}^{\text{DG}}}^{\text{izvori električne energije}} =$$

$$\underbrace{P_t^{\text{grid out}} + \sum_{bess=1}^{BESS} P_{t,bess}^{\text{ch ac}} + P_t^{\text{crit}} + \sum_{l=1}^{L^{\text{stat}}} P_{t,l}^{\text{stat}} + \sum_{l=1}^{L^{\text{dyn}}} P_{t,l}^{\text{dyn}} + \sum_{l=1}^{L^{\text{shft}}} P_{t,l}^{\text{load shft}}}_{\text{trošila električne energije}} \quad \forall t \in T \quad (4\text{-}60)$$

gdje su:

$P_t^{\text{grid in}}$ [kW] – snaga prilikom preuzimanja električne energije iz nadređene elektroenergetske mreže u vremenskom koraku t,

$P_{t,bess}^{\text{disch ac}}$ [kW] – snaga pražnjenja baterijskog sustava pohrane energije *bess* na izmjeničnoj strani u vremenskom koraku t,

$P_{t,pv}^{\text{AC}}$ [kW] – izlazna izmjenična (AC) snaga fotonaponskog sustava *pv* u vremenskom koraku t,

$P_{t,dg}^{\text{DG}}$ [kW] – izlazna snaga upravljivog generatora *dg* u vremenskom koraku t,

$P_t^{\text{grid out}}$ [kW] – snaga prilikom predaje električne energije u nadređenu elektroenergetsku mrežu u vremenskom koraku t,

$P_{t,bess}^{\text{ch ac}}$ [kW] – snaga punjenja baterijskog sustava pohrane energije *bess* na izmjeničnoj strani u vremenskom koraku t,

P_t^{crit} – snaga potrošnje neupravljivih (kritičnih) trošila u vremenskom koraku t,

$P_{t,l}^{\text{stat}}$ [kW] – snaga potrošnje statički upravljivog trošila l u vremenskom koraku t,

$P_{t,l}^{\text{dyn}}$ [kW] – snaga potrošnje dinamički upravljivog trošila l u vremenskom koraku t,

$P_{t,l}^{\text{load shft}}$ [kW] – snaga potrošnje vremenski odgodivog trošila l u vremenskom koraku t.

Izoliran (otočni) pogon mikromreže definira se ograničenjem u izrazu 4-61 u kojem se ograničava snaga razmjene energije između mikromreže i nadređene elektroenergetske mreže u oba smjera na 0 kW (nema razmjene).

$$P_t^{\text{grid in}} = P_t^{\text{grid out}} = 0 \quad (4\text{-}61)$$

4.7. Optimizacijski problem nižeg sloja sustava upravljanja energijom mikromreže

Optimizacijski problem nižeg sloja sustava upravljanja energijom planira pogon mikromreže s ciljem minimizacije odstupanja od planiranih vrijednosti definiranim u višem sloju

nastalih uslijed nesigurnosti procjene ulaznih parametara (prognoze proizvodnje i potrošnje električne energije). Optimizacijski problem realiziran je kao *black-box* problem u kosimulacijskom okruženju opisanom u poglavlju 3.4. Horizont planiranja nižeg sloja sustava upravljanja energijom jednak je horizontu upravljanja (jedan vremenski korak) višeg sloja sustava upravljanja energijom *CH* opisanog u poglavlju 3.2 i vidljivo na slici 3.2. Horizont planiranja diskretiziran je na k vremenskih koraka koji su manje duljine od vremenskog koraka višeg sloja t, a optimizacijski postupak se izvršava korak-po-korak, u jednoj iteraciji, za cijeli horizont planiranja, kako bi se smanjila računalna složenost modela. Optimizacijski problem sastoji se od istih elemenata mikromreže razvijenih u višem sloju te opisanih u potpoglavljima od 4.1 do 4.5. Implementacijom kosimulacijskog okruženja, u kojemu je model mikromreže realiziran u simulacijskom alatu za modeliranje i analizu elektroenergetskih mreža opremljen proračunom (jednadžbama) tokova snaga, omogućen je razvoj detaljnijih modela mikromreže i njenih elemenata od modela u optimizacijskom problemu višeg sloja sustava upravljanja energijom.

4.7.1. Dodatna ograničenja optimizacijskog problema

Implementacijom jednadžbi tokova snaga omogućuje se integracija električkih ograničenja elektroenergetske mreže u pogledu strujno-naponskih prilika unutar mikromreže. Iako jednadžbe tokova snaga također predstavljaju ograničenja optimizacijskog problema, one su neizravno uključene preko simulacijskog alata za modeliranje i analizu elektroenergetskih mreža i u ovom poglavlju neće biti raspisane u tom obliku, nego će se prikazati samo dodatna ograničenja koja one omogućuju.

Za razliku od optimizacijskog problema višeg sloja sustava upravljanja energijom koji mikromrežu modelira kao jednosabirnički sustav u kojemu su svi elementi spojeni na jednu sabirnicu i modeliraju se samo tokovi radne snage, u ovom optimizacijskom problemu se zahvaljujući kosimulacijskom okruženju implementiraju i tokovi jalove snage, a elementi mikromreže su povezani s granama elektroenergetskog sustava (kabeli, vodovi, transformatori). Simulacijski alat za modeliranje i analizu elektroenergetskih mreža *OpenDSS* ima unaprijed razvijene modele svih elemenata mikromreže razvijenih u optimizacijskom problemu višeg sloja sustava upravljanja energijom, dok su zahvaljujući softveru otvorenog koda nekim elementima mikromreže dodane nove funkcionalnosti kako bi odgovarale modelima razvijenim u višem sloju.

Kako je već opisano, kosimulacijsko okruženje između optimizacijske metode i simulacijskog alata za modeliranje i analizu elektroenergetskih mreža omogućuje implementaciju dodatnih električkih ograničenja u pogledu opteretivosti elemenata i naponskih razina u mikromreži. Napon svih čvorova (sabirnica) unutar mikromreže ograničavaju se s obzirom na

dozvoljenu minimalnu i maksimalnu razinu prema izrazu 4-62:

$$V_{bus}^{\min} \leq V_{k,bus} \leq V_{bus}^{\max} \quad \forall k \in K, \forall bus \in BUS \tag{4-62}$$

gdje su:

$V_{k,bus}$ [p.u.] – iznos napona čvora (sabirnice) *bus*, u vremenskom koraku *k*,
$V_{bus}^{\min}$ [p.u.] – minimalni iznos napona čvora (sabirnice) *bus*,
$V_{bus}^{\max}$ [p.u.] – maksimalni iznos napona čvora (sabirnice) *bus*.

Za sve grane mikromreže *ln* modelirani kao kabel ili nadzemni vod definira se ograničenje dozvoljenog strujnog opterećenja prema izrazu 4-63:

$$I_{k,ln} \leq I_{ln}^{\text{nom}} \quad \forall k \in K, \forall ln \in LN \tag{4-63}$$

gdje su:

$I_{k,ln}$ [A] – struja kroz granu (kabel, vod) *ln* u vremenskom koraku *k*,
I_{ln}^{nom} [A] – nazivna struja grane (kabel, vod) *ln*.

Za sve ostale elemente mikromreže *e* definira se ograničenje opteretivosti prividnom snagom prema izrazu 4-64:

$$S_{k,e} \leq \sqrt{P_{k,e}^2 + Q_{k,e}^2} \quad \forall k \in K, \forall e \in E \tag{4-64}$$

gdje su:

$S_{k,e}$ [kVA] – opterećenje prividnom snagom elementa mikromreže *e* u vremenskom koraku *k*,
$P_{k,e}$ [kVA] – opterećenje radnom snagom elementa mikromreže *e* u vremenskom koraku *k*,
$Q_{k,e}$ [kVA] – opterećenje jalovom snagom elementa mikromreže *e* u vremenskom koraku *k*.

Naposlijetku, faktor snage razmijenjene energije između mikromreže i nadređene elektroenergetske mreže (na mjestu priključka) za oba karaktera (induktivni, kapacitivni) ograničava se s obzirom na minimalnu dozvoljenu vrijednost prema izrazu 4-65. Iako ovo ograničenje nema prevelik utjecaj na kratkoročno planiranje pogona mikromreže jer se optimiraju samo tokovi radne snage, ono je uvedeno kao opcija u slučaju da se na mikromrežu žele primijeniti mrežna pravila u pogledu ograničenja faktora snage razmijenjene energije ili da mikromreža sudjeluje u regulaciji jalove snage (napona).

$$\begin{aligned} 1 \geq \cos\varphi_k^{\mathrm{MG}} \geq \cos\varphi_{\mathrm{ind}}^{\mathrm{PCC}} \quad \forall k \in K \\ 1 \geq \cos\varphi_k^{\mathrm{MG}} \geq \cos\varphi_{\mathrm{cap}}^{\mathrm{PCC}} \quad \forall k \in K \end{aligned} \tag{4-65}$$

gdje su:

$\cos\varphi_k^{\mathrm{MG}}$ – faktor snage razmijenjene energije na mjestu priključka mikromreže i nadređene elektroenergetske mreže u vremenskom koraku k,

$\cos\varphi_{\mathrm{ind}}^{\mathrm{MG}}$ – minimalna vrijednost faktora snage u induktivnom području za razmijenjenu energiju na mjestu priključka mikromreže i nadređene elektroenergetske mreže,

$\cos\varphi_{\mathrm{cap}}^{\mathrm{MG}}$ – minimalna vrijednost faktora snage u kapacitivnom području za razmijenjenu energiju na mjestu priključka mikromreže i nadređene elektroenergetske mreže.

4.7.2. Funkcija cilja

Optimizacijski problem višeg sloja sustava upravljanja energijom zadužen je za planiranje ekonomičnog pogona mikromreže s ciljem maksimizacije dobiti mikromreže na osnovu predviđenih ulaznih parametara. Ulazni parametri u optimizacijski problem višeg sloja sustava upravljanja energijom su srednjoročne prognoze meteoroloških parametara za sustave na obnovljive izvore energije (fotonaponski sustav) i potrošnja električne energije, vidljivo na slici 3.2. Viši sloj sustava upravljanja energijom planira pogon za horizont planiranja na razini dana, čime je otporniji na promjene u budućnosti. Da bi se smanjila računalna složenost optimizacijskog problema, viši sloj sustava upravljanja energijom koristi vremenski korak veće duljine čime je neotporan na promjene u bliskoj budućnosti i promjene nastale unutar tog vremenskog koraka. To naposljetku može udaljiti pogon mikromreže od optimalnog, posebice u slučajevima integracije obnovljivih izvora energije čija je proizvodnja nepredvidljiva i ovisi o nesigurnim prognozama meteoroloških parametara. Rješenje ovih oprečnih karakteristika ogleda se u modeliranju optimizacijskog problema suprotnih karakteristika, što je realizirano nižim slojem sustava upravljanja energijom mikromreže. Niži sloj sustava upravljanja energijom ima puno kraći horizont planiranja (jednak horizontu upravljanja višeg sloja), kraći vremenski korak od višeg sloja sustava upravljanja energijom i koristi kratkoročne prognoze (za koje se očekuje da su točnije od srednjoročnih zbog puno kraćeg horizonta planiranja) kao ulazne parametre, čime je otporniji na promjene u bliskoj budućnosti. Kako se za srednjoročne i kratkoročne prognoze koriste različite metode predviđanja, različite duljine horizonta predviđanja i različite frekvencije uzorkovanja,

opisane u poglavlju 4.8, postoji mogućnost pojave razlika u prognozama što može narušiti optimalnost pogona mikromreže definiranog višim slojem sustava upravljanja energijom. Zbog male duljine horizonta planiranja, niži sloj sustava upravljanja energijom nema ekonomski cilj nego tehnički cilj minimizacije korektivnih mjera nastalih uslijed promjena u prognozama ulaznih parametara za sljedeći horizont upravljanja višeg sloja sustava upravljanja energijom. Elementi koji mogu sudjelovati u regulaciji nastalih promjena su mreža (mjesto priključka mikromreže na nadređenu elektroenergetsku mrežu) što također ovisi o načinu pogona mikromreže (umrežen ili izoliran), baterijski sustav pohrane energije i upravljivi generator. Smatra se da niži sloj sustava upravljanja energijom zbog svog kratkog horizonta planiranja ne upravlja snagom potrošnje upravljivih trošila. U slučaju nastalih promjena iz mreže se može preuzeti ili predati više ili manje energije nego što je planirano višim slojem sustava upravljanja energijom, baterijski sustav se može puniti ili prazniti snagama različitim od planiranih vrijednosti, a upravljivi generator može proizvesti manju ili veću količinu energije. Korištenjem kosimulacijskog okruženja koje omogućuje implementaciju jednadžbi tokova snaga i razvoj realnijeg optimizacijskog modela mikromreže bez aproksimacija, niži sloj sustava upravljanja energijom planira pogon mikromreže i s obzirom na električka ograničenja mikromreže.

Optimizacijski problem nižeg sloja sustava upravljanja energijom ima zadatak zadržati omjere (udjele) proizvodnje odnosno potrošnje električne energije upravljivih elemenata mikromreže definiranih višim slojem sustava upravljanja energijom za sljedeći horizont upravljanja, uz osvježene (kratkoročne) prognoze ulaznih parametara, čime se pogon mikromreže prilagođava nastalim promjenama. Kako se kod modela elemenata mikromreže s dvosmjernim tokovima energije (mreža i baterijski sustav pohrane energije) u višem sloju sustava upravljanja posebno definiraju varijable snage za svaki smjer energije, za potrebe formiranja funkcije cilja optimizacijskog problema nižeg sloja sustava upravljanja energijom definiraju se nove varijable koje prikazuju neto razmijenjenu snagu elementa. Prema tome se za mrežu (mjesto priključka mikromreže na nadređenu elektroenergetsku mrežu) definira neto snaga razmjene $P_t^{\text{grid net}}$ prema izrazu 4-66. Ako je neto snaga razmijenjene energije između mikromreže i nadređene elektroenergetske mreže pozitivna, mikromreža preuzima energiju iz nadređene elektroenergetske mreže u iznosu $P_t^{\text{grid in}}$. U slučaju negativne vrijednosti mikromreža predaje energiju u nadređenu elektroenergetsku mrežu snagom $P_t^{\text{grid out}}$. Neto snaga baterijskog sustava pohrane energije $P_{t,bess}^{\text{BESS net}}$ definira se prema izrazu 4-67. Ako je neto snaga baterijskog sustava pohrane energije pozitivna, baterijski sustav pohrane energije se prazni snagom $P_{t,bess}^{\text{disch ac}}$, a ako je negativna, baterijski sustav pohrane energije se puni snagom $P_{t,bess}^{\text{ch ac}}$.

$$P_t^{\text{grid net}} = P_t^{\text{grid in}} - P_t^{\text{grid out}} \quad \forall t \in T \tag{4-66}$$

$$P_{t,bess}^{\text{BESS net}} = P_{t,bess}^{\text{disch ac}} - P_{t,bess}^{\text{ch ac}} \quad \forall t \in T, \forall bess \in BESS \tag{4-67}$$

Kako niži sloj sustava upravljanja energijom ne upravlja potrošnjom električne energije (upravljivim trošilima) zbog relativno kratkog horizonta planiranja, za potrebe formiranja funkcije cilja definira se varijabla ukupne potrošnje svih vrsta trošila mikromreže. Ukupna potrošnja $P_t^{\text{load total}}$ je definirana prema izrazu 4-68 kao zbroj snage potrošnje neupravljive potrošnje P_t^{crit}, snage potrošnje statički upravljivih trošila $P_{t,l}^{\text{stat}}$, snage potrošnje dinamički upravljivih trošila $P_{t,l}^{\text{dyn}}$ i snage potrošnje vremenski odgodivih trošila $P_{t,l}^{\text{shift}}$.

$$P_t^{\text{load total}} = P_t^{\text{crit}} + \sum_{l=1}^{L^{\text{stat}}} P_{t,l}^{\text{stat}} + \sum_{l=1}^{L^{\text{dyn}}} P_{t,l}^{\text{dyn}} + \sum_{l=1}^{L^{\text{shft}}} P_{t,l}^{\text{load shft}} \quad \forall t \in T \tag{4-68}$$

Kako bi se otklonio utjecaj pozitivnih i negativnih vrijednosti neto razmijenjene snage (kod elemenata s dvosmjernim tokovima energije) te razlike u instaliranim kapacitetima svih upravljivih elemenata mikromreže (mreža, baterijski sustav pohrane energije i upravljivi generator) za potrebe formiranja funkcije cilja, sve vrijednosti snaga elemenata u oba sloja sustava upravljanja energijom normaliziraju se na vrijednost između 0 i 1 prema izrazu 4-69:

$$p_i = \frac{P_i - \min(P)}{\max(P) - \min(P)} \quad \forall i \in I, p_i \in [0, 1] \tag{4-69}$$

gdje su:

- p_i – normalizirana veličina u koraku i,
- P_i – izvorna (originalna) veličina u koraku i,
- $\min(P)$ – minimalna vrijednost veličine s obzirom na koju se izvorna veličina normalizira,
- $\max(P)$ – maksimalna vrijednost veličine s obzirom na koju se izvorna veličina normalizira.

Snage upravljivih elemenata definirane nakon optimizacijskog postupka (varijable odluke) višeg sloja sustava upravljanja energijom (referentne veličine) normaliziraju se prema izrazu 4-69, a njihov analitički zapis je vidljiv u izrazu 4-70. Treba zamijetiti da se prema izrazu 4-69 sve snage upravljivih elemenata svode na isti raspon minimalne i maksimalne vrijednosti. Veličina s obzirom na koju se vrijednosti normaliziraju mora imati najveći raspon između minimalne i maksimalne vrijednosti svih upravljivih elemenata mikromreže kako bi normalizirane vrijednosti uvijek poprimile vrijednost između 0 i 1 te se uklonile razlike u

instaliranim kapacitetima. U ovoj disertaciji sve snage će se normalizirati s obzirom na priključne snage mikromreže na nadređenu elektroenergetsku mrežu jer je njihov raspon snaga najveći. U slučaju da postoji element mikromreže s većim rasponom snaga, ostale veličine snaga se trebaju normalizirati s obzirom na raspon te veličine. Maksimalnu snagu u izrazu 4-70 predstavlja priključna snaga mikromreže u smjeru preuzimanja električne energije u nadređenu elektroenergetsku mrežu $P^{\text{grid in max}}$, a minimalnu snagu predstavlja priključna snaga mikromreže u smjeru predaje električne energije u nadređenu elektroenergetsku mrežu $P^{\text{grid out max}}$. Također, treba primijetiti da se i u brojniku i nazivniku izraza 4-70 umjesto oduzimanja maksimalne snage od minimalne, koristi operacija zbrajanja. Razlog korištenja zbrajanja je razlika u prirodi veličina korištenih u izrazima 4-69 i 4-70. U izrazu 4-69 se smatra da veličina P može poprimiti i pozitivne i negativne iznose. Kako su veličine $P_t^{\text{grid in max}}$ i $P_t^{\text{grid out max}}$ korištene u izrazu 4-70 uvijek pozitivni realni brojevi to znači da, ako se želi dobiti raspon veličina, u brojniku i nazivniku izraza se mora koristiti operacija zbrajanja.

$$
\begin{aligned}
p_t^{\text{grid norm}} &= \frac{P_t^{\text{grid net}} + P_t^{\text{grid out max}}}{P_t^{\text{grid in max}} + P_t^{\text{grid out max}}} && \forall t \in T \\
p_{t,bess}^{\text{BESS norm}} &= \frac{P_{t,bess}^{\text{BESS net}} + P_t^{\text{grid out max}}}{P_t^{\text{grid in max}} + P_t^{\text{grid out max}}} && \forall t \in T, \forall bess \in BESS \\
p_{t,dg}^{\text{DG norm}} &= \frac{P_{t,dg}^{\text{DG}} + P_t^{\text{grid out max}}}{P_t^{\text{grid in max}} + P_t^{\text{grid out max}}} && \forall t \in T, \forall dg \in DG
\end{aligned}
\tag{4-70}
$$

gdje su:

- $p_t^{\text{grid norm}}$ – normalizirana veličina snage razmijene energije između mikromreže i nadređene elektroenergetske mreže u vremenskom koraku t,
- $p_{t,bess}^{\text{BESS norm}}$ – normalizirana veličina snage baterijskog sustava pohrane energije $bess$ u vremenskom koraku t,
- $p_{t,dg}^{\text{DG norm}}$ – normalizirana veličina izlazne snage upravljivog generatora dg u vremenskom koraku t,
- $P_t^{\text{grid net}}$ [kW] – neto snaga razmijene energije između mikromreže i nadređene elektroenergetske mreže u vremenskom koraku t,
- $P_{t,bess}^{\text{BESS net}}$ [kW] – neto snaga baterijskog sustava pohrane energije $bess$ u vremenskom koraku t,
- $P_{t,dg}^{\text{DG}}$ [kW] – izlazna snaga upravljivog generatora dg u vremenskom koraku t.

Ista metodologija se primjenjuje na snage upravljivih elemenata mikromreže u nižem sloju sustava upravljanja energijom čiji je analitički zapis vidljiv u izrazu 4-71. Varijable $P_k^{\text{BESS net}}$ i P_k^{DG} su varijable odluke ovog optimizacijskog problema dok je varijabla $P_k^{\text{grid net}}$

varijabla stanja jer je ona rezultat varijabli odluka. Njena vrijednost ovisi o postavljenim varijablama odluka unutar modela mikromreže realiziranom u simulacijskom alatu za modeliranje i analizu elektroenergetskih mreža. Njen numerički iznos jednak je razlici između proizvedene i potrošene snage (zajedno sa mrežnim gubicima) unutar mikromreže, a dobiva se postupkom proračuna tokova snaga. Razlika u odnosu na izraz 4-70 je u indeksu veličina gdje se za vremenski korak koristi k umjesto t.

$$\begin{aligned} p_k^{\text{grid norm}} &= \frac{P_k^{\text{grid net}} + P_k^{\text{grid out max}}}{P_k^{\text{grid in max}} + P_k^{\text{grid out max}}} && \forall k \in K \\ p_{k,bess}^{\text{BESS norm}} &= \frac{P_{k,bess}^{\text{BESS net}} + P_k^{\text{grid out max}}}{P_k^{\text{grid in max}} + P_k^{\text{grid out max}}} && \forall k \in K, \forall bess \in BESS \\ p_{k,dg}^{\text{DG norm}} &= \frac{P_{k,dg}^{\text{DG}} + P_k^{\text{grid out max}}}{P_k^{\text{grid in max}} + P_k^{\text{grid out max}}} && \forall k \in K, \forall dg \in DG \end{aligned} \tag{4-71}$$

gdje su:

$p_k^{\text{grid norm}}$ – normalizirana veličina snage razmijene energije između mikromreže i nadređene elektroenergetske mreže u vremenskom koraku k,

$p_{k,bess}^{\text{BESS norm}}$ – normalizirana veličina snage baterijskog sustava pohrane energije $bess$ u vremenskom koraku k,

$p_{k,dg}^{\text{DG norm}}$ – normalizirana veličina izlazne snage upravljivog generatora dg u vremenskom koraku k,

$P_k^{\text{grid net}}$ [kW] – neto snaga razmijene energije između mikromreže i nadređene elektroenergetske mreže u vremenskom koraku k,

$P_{k,bess}^{\text{BESS net}}$ [kW] – neto snaga baterijskog sustava pohrane energije $bess$ u vremenskom koraku k,

$P_{k,dg}^{\text{DG}}$ [kW] – izlazna snaga upravljivog generatora dg u vremenskom koraku k.

Nakon normaliziranja veličina snaga višeg i nižeg sloja sustava upravljanja energijom, mogu se definirati omjeri (udjeli) proizvodnje odnosno potrošnje električne energije upravljivih elemenata mikromreže u ukupnoj proizvodnji/potrošnji energije svih upravljivih elemenata mikromreže potrebni za formiranje funkcije cilja. Omjeri su veličine koje poprimaju iznos između 0 i 1. Analitički zapis omjera (udjela) proizvodnje/potrošnje upravljivih elemenata u višem sloju sustava upravljanja energijom (referentne veličine) vidljiv je u izrazu 4-72, a nižeg sloja sustava upravljanja energijom (varijable odluke) u izrazu 4-73.

$$
\begin{aligned}
R_t^{\text{grid}} &= \frac{p_t^{\text{grid norm}}}{p_t^{\text{grid norm}} + \sum_{bess=1}^{BESS} p_{t,bess}^{\text{BESS norm}} + \sum_{dg=1}^{DG} p_{t,dg}^{\text{DG norm}}} && \forall t \in T \\
R_{t,bess}^{\text{BESS}} &= \frac{p_{t,bess}^{\text{BESS norm}}}{p_t^{\text{grid norm}} + \sum_{bess=1}^{BESS} p_{t,bess}^{\text{BESS norm}} + \sum_{dg=1}^{DG} p_{t,dg}^{\text{DG norm}}} && \forall t \in T, \forall bess \in BESS \\
R_{t,dg}^{\text{DG}} &= \frac{p_{t,dg}^{\text{DG norm}}}{p_t^{\text{grid norm}} + \sum_{bess=1}^{BESS} p_{t,bess}^{\text{BESS norm}} + \sum_{dg=1}^{DG} p_{t,dg}^{\text{DG norm}}} && \forall t \in T, \forall dg \in DG
\end{aligned}
\tag{4-72}
$$

gdje su:

R_t^{grid} – omjer (udjel) proizvodnje/potrošnje (snaga preuzimanja/predaje energije) elementa mreže (mjesto priključka mikromreže na nadređenu elektroenergetsku mrežu) u vremenskom koraku t,

$R_{t,bess}^{\text{BESS}}$ – omjer (udjel) proizvodnje/potrošnje (snaga pražnjenja/punjenja) baterijskog sustava pohrane energije *bess* u vremenskom koraku t,

$R_{t,dg}^{\text{DG}}$ – omjer (udjel) snage proizvodnje upravljivog generatora *dg* u vremenskom koraku t.

$$
\begin{aligned}
R_k^{\text{grid}} &= \frac{p_k^{\text{grid norm}}}{p_k^{\text{grid norm}} + \sum_{bess=1}^{BESS} p_{k,bess}^{\text{BESS norm}} + \sum_{dg=1}^{DG} p_{k,dg}^{\text{DG norm}}} && \forall k \in K \\
R_{k,bess}^{\text{BESS}} &= \frac{p_{k,bess}^{\text{BESS norm}}}{p_k^{\text{grid norm}} + \sum_{bess=1}^{BESS} p_{k,bess}^{\text{BESS norm}} + \sum_{dg=1}^{DG} p_{k,dg}^{\text{DG norm}}} && \forall k \in K, \forall bess \in BESS \\
R_{k,dg}^{\text{DG}} &= \frac{p_{k,dg}^{\text{DG norm}}}{p_k^{\text{grid norm}} + \sum_{bess=1}^{BESS} p_{k,bess}^{\text{BESS norm}} + \sum_{dg=1}^{DG} p_{k,dg}^{\text{DG norm}}} && \forall k \in K, \forall dg \in DG
\end{aligned}
\tag{4-73}
$$

gdje su:

R_k^{grid} – omjer (udjel) proizvodnje/potrošnje (snaga preuzimanja/predaje energije) elementa mreže (mjesto priključka mikromreže na nadređenu elektroenergetsku mrežu) u vremenskom koraku k,

$R_{k,bess}^{\text{BESS}}$ – omjer (udjel) proizvodnje/potrošnje (snaga pražnjenja/punjenja) baterijskog sustava pohrane energije *bess* u vremenskom koraku k,

$R_{k,bess}^{\text{DG}}$ – omjer (udjel) snage proizvodnje upravljivog generatora *dg* u vremenskom koraku k.

Analitički zapis funkcije cilja optimizacijskog problema nižeg sloja sustava upravljanja energijom mikromreže vidljiv je u izrazu 4-74. Cilj optimizacijskog problema je minimizirati razliku između omjera (udjela) proizvodnje/potrošnje energije upravljivih elemenata definiranih u višem sloju sustava upravljanja energijom (referentne vrijednosti) i omjera (udjela)

proizvodnje/potrošnje energije upravljivih elemenata nižeg sloja sustava upravljanja energijom, što su ujedno i varijable odluke optimizacijskog problema nižeg sloja. Globalni optimum funkcije cilja iznosi 0 jer će u tom slučaju omjeri biti izjednačeni.

$$\text{minimiziraj} \quad \sum_{k=1}^{K} \left[\left(R_t^{\text{grid}} - R_k^{\text{grid}} \right) + \sum_{bess=1}^{BESS} \left(R_{t,bess}^{\text{BESS}} - R_{k,bess}^{\text{BESS}} \right) + \sum_{dg=1}^{DG} \left(R_{t,dg}^{\text{DG}} - R_{k,dg}^{\text{DG}} \right) \right] \quad (4\text{-}74)$$

4.8. Predviđanje ulaznih parametara u optimizacijske probleme

Podsustav sustava upravljanja energijom mikromreže predstavlja modul za predviđanje ulaznih parametara u optimizacijske probleme (slojeve). Kako bi se povećala realnost modeliranog sustava upravljanja energijom, u ovoj disertaciji će se koristiti različite metode predviđanja ulaznih parametara čiji kratki opis slijedi u nastavku.

4.8.1. Metode predviđanja ulaznih parametara u optimizacijski problem višeg sloja sustava upravljanja energijom

U ovom poglavlju će biti opisane metode korištene za srednjoročnu prognozu potrošnje električne energije mikromreže i srednjoročne prognoze snage sunčevog zračenja i temperature okoliša koje služe kao ulazni podaci u optimizacijski problem višeg sloja sustava upravljanja energijom.

Srednjoročna prognoza snage sunčevog zračenja i temperature okoliša pomoću GFS-a

U ovoj disertaciji se koriste numerički modeli predviđanja vremenskih prilika (engl. *Numerical Weather Prediction*) za srednjoročnu prognozu snage sunčevog zračenja i temperature okoliša. Za preuzimanje srednjoročnih prognoza u ovoj disertaciji koristi se javno dostupni servis *Global Forecasting System* (GFS) održavan od strane agencije SAD-a *National Weather Service* (NWS). Numerički modeli servisa vrše prognoze 4 puta dnevno (svakih 6 sati) i omogućuju dohvaćanje prognoza za 16 dana unaprijed s rezolucijom od 3 sata za bilo koju geografsku lokaciju na Zemlji i u horizontalnoj rezoluciji do 0.25 °(28 km) [105]. Dohvaćanje prognoza u ovoj disertaciji realizirano je pomoću aplikacijskog programskog sučelja ugrađenog u paket *pvlib python* [106] za viši programski jezik *Python*. Paket *pvlib python* je skupina funkcija razvijenih za simulaciju performansi fotonaponskih sustava inicijalno razvijen za *MATLAB* od strane *Sandia National Laboratories* [107]. Prognoze se preko aplikacijskog programskog sučelja dohvaćaju u obliku razine naoblake i vanjske temperature

za specificiranu lokaciju u željenom intervalu u budućnosti. Kako bi se generirala prognoza snage sunčevog zračenja na specificiranoj lokaciji, moraju se koristiti modeli pretvorbe razine naoblake u snagu sunčevog zračenja. Paket *pvlib python* omogućuje korištenje Campbell-Norman modela predstavljenog u [108] za pretvorbu dohvaćenih prognoza naoblake u profile snage globalnog horizontalnog sunčevog zračenja (engl. *Global Horizontal Irradiance - GHI*), snage izravnog normalnog sunčevog zračenja (engl. *Direct Normal Irradiance - DNI*) i snage difuznog horizontalnog sunčevog zračenja (engl. *Diffuse Horizontal Irradiance - DHI*). Za potrebe ulaznih podataka u model fotonaponskog sustava opisanog u poglavlju 4.3 će se koristiti profil snage globalnog horizontalnog sunčevog zračenja i temperature okoliša.

Primjer prognoza profila globalnog horizontalnog sunčevog zračenja (G) i temperature okoliša (ϑ) za mikrolokaciju zgrade Fakulteta elektrotehnike, računarstva i informacijskih tehnologija (FERIT) Osijek s koordinatama 45°33'24.2"N, 18°41'45.1"E za razdoblje od 31. prosinca 2021. 00:00 sati do 2. siječnja 2022 00:00 sati (2 dana) vidljiv je na slici 4.15. Prognoze su preuzete dan ranije.

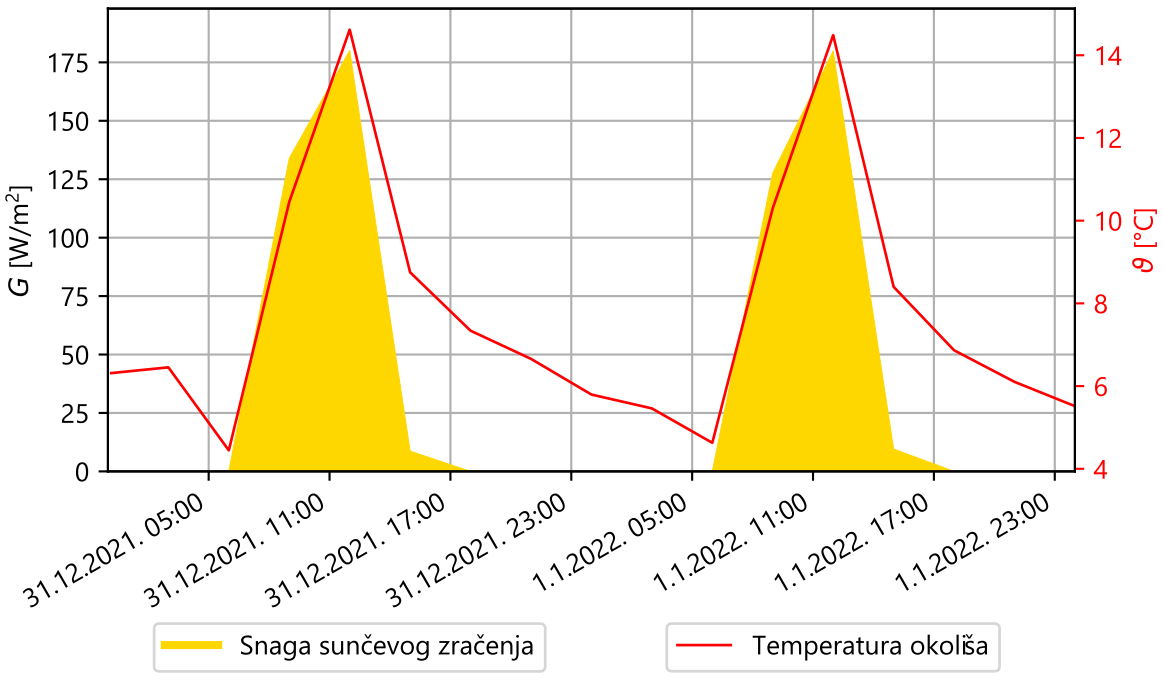

Slika 4.15: *Prognoza snage globalnog horizontalnog sunčevog zračenja i temperature okoliša za mikrolokaciju zgrade FERIT-a Osijek za razdoblje od 31. prosinca 2021. 00:00 sati do 2. siječnja 2022. 00:00 sati pomoću GFS servisa*

Srednjoročno prognoziranje potrošnje električne energije mikromreže pomoću umjetnih neuronskih mreža s dugom kratkoročnom memorijom

Umjetne neuronske mreže predstavljaju široko rasprostranjenu skupinu metoda dubokog učenja (engl. *Deep learning*). Umjetne neuronske mreže su nadahnute funkcioniranjem

ljudskog mozga koji se sastoji od neodređenog broja neurona. Osnovni građevni dio umjetne neuronske mreže su neuroni organizirani u jedan ili više slojeva različite vrste. Jedan sloj neuronske mreže sastoji se od minimalno dva neurona. Umjetne neuronske mreže uglavnom se sastoje od više međusobno povezanih slojeva (engl. *Layer*), a najčešći oblik je kombinacija ulaznog sloja (engl. *Input layer*) neurona, jednog ili više skrivenih slojeva (engl. *Hidden layer*) neurona i izlaznog sloja (engl. *Output layer*) neurona. Postoje mnoge vrste umjetnih neuronskih mreža dizajniranih za određene namjene. Detaljan opis principa djelovanja i namjene različitih umjetnih neuronskih mreža dostupan je u [109].

Predviđanje potrošnje električne energije mikromreže u ovoj disertaciji se vrši umjetnom neuronskom mrežom s dugom kratkoročnom memorijom (engl. *Long Short-Term Memory* - LSTM), tipom umjetnih neuronskih mreža s povratnom vezom (engl. *Recurrent neural network*) [109]. Detaljan opis djelovanja umjetne neuronske mreže s dugom kratkročnom memorijom dostupan je u [110], a osnovna ideja je reguliranje internog stanja ćelije. U ovom poglavlju će se opisati osnovni principi djelovanja ovog tipa umjetnih neuronskih mreža.

Osnovni dio umjetne neuronske mreže su ćelije s dugom kratkoročnom memorijom - LSTM ćelije. LSTM ćelije imaju ugrađenu vlastitu povratnu vezu (engl. *Self-loop*) uz dodatnu vanjsku povratnu vezu. Svaka ćelija ima iste ulaze i izlaze kao i klasični neuron u neuronskoj mreži s povratnom vezom, ali ima i dodatni skup parametara kojima se kontrolira tok informacija i nazivaju se regulatori odnosno vrata (engl. *Gate*). Osnovna struktura LSTM ćelije je prikazana na slici 4.16 [109].

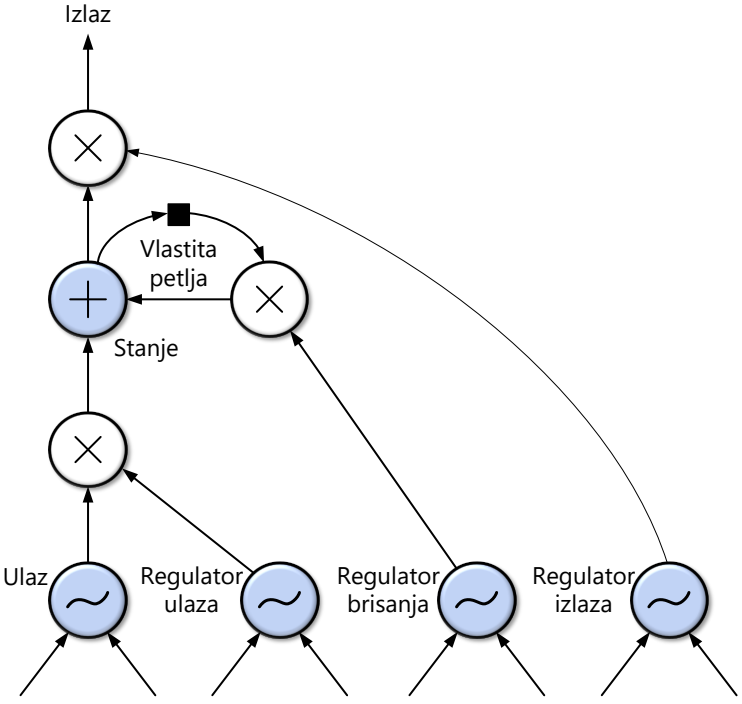

Slika 4.16: *Struktura LSTM ćelije*

LSTM ćelija je opisana s tri vrste dodatnih parametara nazvanih regulator ulaza (engl. *Input gate*), regulator brisanja (engl. *Forget gate*) i regulator izlaza (engl. *Output gate*). Crni kvadrat na slici 4.16 predstavlja kašnjenje (engl. *Delay*) od jednog koraka u slijedu podataka koji ne mora nužno značiti vremenski korak. Svi regulatori koriste sigmoidnu (logističku) prijenosnu funkciju za generiranje težinskog koeficijenta koji poprimaju vrijednost između 0 i 1. Analitički zapis vrijednosti sigmoidne funkcije σ varijable x vidljiv je u izrazu 4-75. Ovim težinskim koeficijentima se regulira utjecaj informacija na izlaz iz LSTM ćelije [109].

$$\sigma(x) = \frac{1}{1 + e^{-x}} \tag{4-75}$$

Analitički zapis internog stanja LSTM ćelije i u vremenskom trenutku t ($s_i^{(t)}$) definiran je izrazom 4-76 [109] gdje $x^{(t)}$ predstavlja trenutni ulazni vektor podataka, $h^{(t)}$ predstavlja trenutni vektor skrivenog sloja, b predstavlja pragove (engl. *Biases*), U težinske koeficijente ulaznih podataka (engl. *Input weights*), a W težinske koeficijente povratne veze (engl. *Recurrent weights*) u LSTM ćeliju. Operator σ predstavlja primjenu sigmoidne (nelinearne) prijenosne funkcije za generiranje izlaza s vrijednostima između 0 i 1. Težinski koeficijent vlastite petlje LSTM ćelije upravlja se regulatorom brisanja $f_i^{(t)}$ čiji je analitički zapis definiran izrazom 4-77. Stanje regulatora ulaza $g_i^{(t)}$ analitički se određuje slično kao stanje regulatora brisanja $f_i^{(t)}$, a težinski koeficijent se određuje prema izrazu 4-78. Izaz iz LSTM ćelije $h_i^{(t)}$ analitički se određuje prema izrazu 4-79 i ovisi o internom stanju ćelije $s_i^{(t)}$, a može se upravljati i težinskim koeficijentom regulatorom izlaza $q_i^{(t)}$ čije se stanje određuje prema izrazu 4-80 [109].

$$s_i^{(t)} = f_i^{(t)} s_i^{(t-1)} + g_i^{(t)} \sigma \left(b_i + \sum_j U_{i,j} x_j^{(t)} + \sum_j W_{i,j} h_j^{(t-1)} \right) \tag{4-76}$$

$$f_i^{(t)} = \sigma \left(b_i^f + \sum_j U_{i,j}^f x_j^{(t)} + \sum_j W_{i,j}^f h_j^{(t-1)} \right) \tag{4-77}$$

$$g_i^{(t)} = \sigma \left(b_i^g + \sum_j U_{i,j}^g x_j^{(t)} + \sum_j W_{i,j}^g h_j^{(t-1)} \right) \tag{4-78}$$

$$h_i^{(t)} = \text{th} \left(s_i^{(t)} \right) q_i^{(t)} \tag{4-79}$$

$$q_i^{(t)} = \sigma \left(b_i^o + \sum_j U_{i,j}^o x_j^{(t)} + \sum_j W_{i,j}^o h_j^{(t-1)} \right) \tag{4-80}$$

Kako su umjetne neuronske mreže podatkovno orijentirane i adaptivne metode za predviđanje veličina, učenje o međusobnoj povezanosti ulaznih i izlaznih veličina postiže se pomoću procesa treniranja (učenja). Proces treniranja podešava težinske koeficijente neuronske mreže sve dok se ne postigne odgovarajuća točnost predviđanja i predstavlja optimizacijski problem. Postoje dvije vrste treniranja umjetnih neuronskih mreža, nadzirano učenje (engl. *Supervised learning*) i nenadzirano učenje (engl. *Unsupervised learning*). Nadzirano učenje neuronske mreže odvija se uz predviđanje unaprijed poznate izlazne veličine dok kod nenadziranog učenja izlazne veličine nisu poznate. Proces nadziranog treniranja neuronske mreže zasniva se na razlici između predviđene i stvarne veličine koja se predviđa čime se računa točnost odnosno pogreška predviđanja. Pogreška predviđanja se numerički izražava pomoću vrijednosti funkcije gubitka (engl. *Loss function*) koju optimizacijski proces minimizira ili maksimizira tijekom procesa treniranja. Ako bi se povukla analogija s teorijom optimizacijskih problema, funkcija gubitka predstavlja funkciju cilja, a težinski koeficijenti predstavljaju varijable odluke optimizacijskog problema. Kako bi se informacija o pogrešci predviđanja prenijela svim elementima neuronske mreže, a težinski faktori podesili, koristi se proces unatražnog rasprostiranja (engl. *Back-propagation*). Većina optimizacijskih problema koji se rješavaju prilikom treniranja umjetnih neuronskih mreža rješava se pomoću raznih verzija programa za numeričko rješavanje (engl. *Solver*) zasnovanih na stohastičkom gradijentnom spustu (engl. *Stochastic gradient descent*). Detaljan opis procesa treniranja umjetnih neuronskih mreža dostupan je u [109], a opis najkorištenijih programa za numeričko rješavanje optimizacijskih problema prilikom treniranja dostupan je u [111].

Prije treniranja umjetne neuronske mreže svi se ulazni podaci trebaju obraditi na način da se izbjegnu dimenzijske razlike između ulaznih veličina. Ovim postupkom se uklanja utjecaj ulaznih veličina većih dimenzija na izlaznu (predviđenu) veličinu od veličina manjih dimenzija. Prema tome, svi ulazni podaci će se normalizirati na vrijednost između 0 i 1 prema izrazu 4-81 gdje y_i predstavlja i-ti uzorak normalizirane veličine, x_i predstavlja i-ti uzorak originalne veličine, $x^{\min}$ predstavlja minimalnu vrijednost svih uzoraka x_i, a $x^{\min}$ maksimalnu vrijednost svih uzoraka x_i.

$$y_i = \frac{x_i - x^{\min}}{x^{\max} - x^{\min}} \tag{4-81}$$

Najzahtjevniji problem prilikom modeliranja umjetne neuronske mreže predstavlja odabir ulaznih veličina (prediktora) na osnovu kojih se predviđa izlazna veličina, odabir arhitekture u smislu broja skrivenih slojeva i broja neurona (LSTM ćelija) po pojedinim slojevima, odabir aktivacijskih funkcija pojedinih slojeva, odabir programa za numeričko rješavanje (engl. *Solver*) i odabir funkcije gubitka. Sve ove karakteristike umjetne neuronske mreže određene

su uz pomoć dostupne literature i metodom pokušaja i pogreške na temelju kvalitete rezultata predviđanja.

Umjetna neuronska mreža s dugom kratkoročnom memorijom u ovoj doktorskoj disertaciji će se trenirati pomoću nadziranog učenja. Pogreška predviđanja tijekom treniranja će se numerički izražavati pomoću funkcije gubitka predstavljene kao srednja apsolutna pogreška (engl. *Mean Absolute Error - MAE*) prikazane u izrazu 4-82.

$$MAE = \frac{1}{N}\sum_{i=1}^{N}\left|I_i^{\text{meas}} - I_i^{\text{pred}}\right| \tag{4-82}$$

Osim srednje apsolutne pogreške, za ocjenu performansi (točnost) predviđanja umjetne neuronske mreže, koristit će se dodatna dva statistička indeksa pogreške: korijen srednje kvadratne pogreške (engl. *Root Mean Square Error* - RMSE) prikazane u izrazu 4-83 i koeficijent korelacije (engl. *Correlation coefficient* - R) prikazan u izrazu 4-84.

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(I_i^{\text{meas}} - I_i^{\text{pred}}\right)^2} \tag{4-83}$$

$$R = \frac{\frac{1}{N}\sum_{i=1}^{N}\left(I_i^{\text{meas}} - \overline{I}^{\text{meas}}\right)\cdot\left(I_i^{\text{pred}} - \overline{I}^{\text{pred}}\right)}{\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(I_i^{\text{meas}} - \overline{I}^{\text{meas}}\right)^2}\cdot\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(I_i^{\text{pred}} - \overline{I}^{\text{pred}}\right)^2}} \tag{4-84}$$

gdje su:

i – broj uzorka,
N – ukupan broj uzoraka,
I_i^{meas} – izmjerena (stvarna) vrijednost uzorka i,
I_i^{pred} – predviđena vrijednost uzorka i,
$\overline{I}^{\text{meas}}$ – srednja vrijednost izmjerenih (stvarnih) uzoraka,
$\overline{I}^{\text{pred}}$ – srednja vrijednost predviđenih uzoraka.

4.8.2. Metode predviđanja ulaznih parametara u optimizacijski problem nižeg sloja sustava upravljanja energijom

Ulazni parametri u optimizacijski problem nižeg sloja sustava upravljanja energijom koji se predviđaju su kratkoročne prognoze potrošnje električne energije mikromreže i meteoroloških parametara za sustave na obnovljive izvore energije (snaga sunčevog zračenja i temperatura okoliša), za horizont predviđanja PH_i. Horizont predviđanja PH_i nižeg sloja sustava upravljanja energijom je, prema slici 3.1, jednak horizontu upravljanja CH_i višeg

sloja sustava upravljanja energijom. Za predviđanje ulaznih parametara u optimizacijski problem nižeg sloja sustava upravljanja energije koriste se umjetne neuronske mreže s dugom kratkoročnom memorijom. Ista vrsta korištena je za predviđanje potrošnje električne energije mikromreže u višem sloju opisana u poglavlju 4.8.1. Razlike u odnosu na umjetnu neuronsku mrežu korištenu u višem sloju su različite ulazne i izlazne veličine, dok je horizont predviđanja puno kraći i jednak horizontu upravljanja višeg sloja sustava upravljanja energijom.

5. Vrednovanje unaprijeđenog dvoslojnog sustava upravljanja energijom planiranjem kratkoročnog pogona testne mikromreže

U ovom poglavlju vrednovan je razvijeni dvoslojni sustav upravljanja energijom planiranjem kratkoročnog pogona testne mikromreže, opisane su postavke optimizacijskog okvira, testna mikromreža i postavke simulacijskih slučajeva, a rezultati simulacija su grafički i analitički analizirani. Simulacije se vrše za jedan karakterističnu radni dan u tjednu.

5.1. Postavke optimizacijskog okvira i optimizacijskih metoda

Predstavljeni dvoslojni sustav upravljanja energijom koristi se za kratkoročno planiranje pogona testne mikromreže s horizontom planiranja višeg sloja SH_i i horizontom predviđanja PH_i duljine 24 sata. Vremenski korak višeg sloja sustava upravljanja energijom iznosi 10 minuta unutar kojeg se iznosi veličina smatraju nepromjenjivima. Horizont upravljanja za koji se generirane varijable odluke prosljeđuju nižem sloju kao referentne vrijednosti iznosi jedan vremenski korak odnosno 10 minuta. Kako je horizont planiranja optimizacijskog problema nižeg sloja jednak horizontu upravljanja višeg sloja, on iznosi 10 minuta dok vremenski korak iznosi 1 minutu. Postavke optimizacijskog okvira su grafički prikazane na slici 5.1.

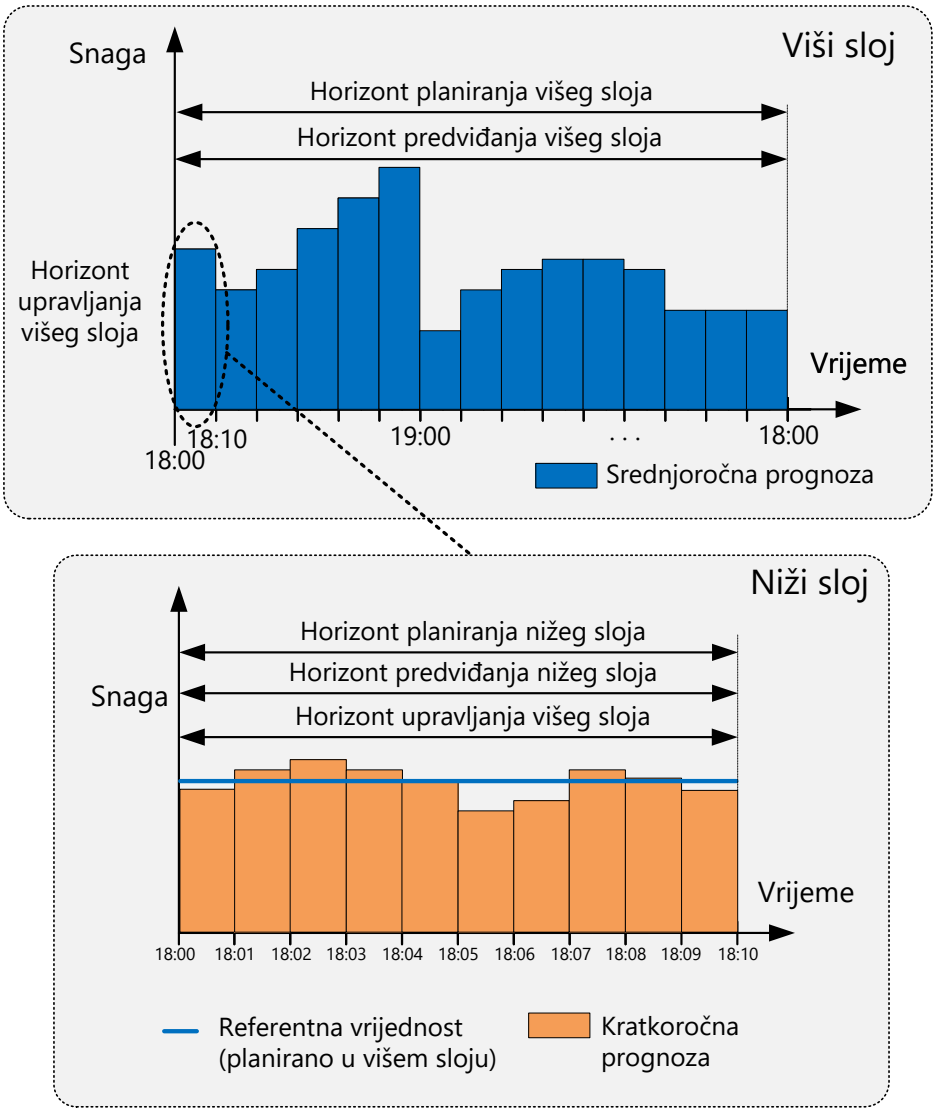

Slika 5.1: *Postavke optimizacijskog okvira korištenog za vrednovanje dvoslojnog sustava upravljanja energijom*

Optimizacijska metoda primijenjena u optimizacijskom problemu nižeg sloja sustava upravljanja energijom mikromreže (optimizacija rojem čestica) koristi populaciju s 50 jedinki (čestica), a proces pronalaska rješenja ponavlja se 50 puta (broj generacija jedinki). Ove karakteristike određene su izvršavanjem velikog broja simulacija, dok se ne postignu zadovoljavajući rezultati (minimalna vrijednost funkcije cilja) uz što manje vrijeme izvođenja optimizacijskog postupka.

5.2. Opis testne mikromreže

Modelirani sustav upravljanja energijom, koji omogućuje i umrežen i izoliran (otočni) pogon, primijenjen je za kratkoročno planiranje pogona izmjenične (AC) mikromreže kao najzastupljenijeg tipa mikromreže u praksi. Testna mikromreža predstavlja elektroener-

getsku mrežu komercijalne zgrade koja se sastoji od proizvođačko/potrošačkih elemenata spojenih na nadređenu (distribucijsku) elektroenergetsku mrežu preko mjesta priključka.

Testna mikromreža sastoji se od sljedećih elemenata:

- Mreža (mjesto priključka mikromreže na nadređenu elektroenergetsku mrežu);
- Baterijski sustav pohrane energije;
- Upravljivi generator;
- Trošila.

U nastavku slijedi opis tehničkih karakteristika modeliranih elementa testne mikromreže korištenih za referentni slučaj.

5.2.1. Tehničke karakteristike elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu) za referentni slučaj

U referentnom slučaju testna mikromreža se integrira u distribucijsku elektroenergetsku mrežu kao subjekt na koju se primjenjuje regulativa za aktivne kupce odnosno krajnje kupce s vlastitom proizvodnjom (engl. *Prosumer*) i mrežna pravila distribucijskog sustava u Republici Hrvatskoj. Mrežna pravila distribucijskog sustava definira Hrvatska Elektroprivreda (HEP) - Operator distribucijskog sustava (ODS) kojima se uređuju tehnički uvjeti priključenja korisnika distribucijske mreže na elektroenergetsku distribucijsku mrežu, planiranje razvoja mreže, pogon i način vođenja mreže te korištenje mreže [112, 113]. Regulativa za krajnje kupce s vlastitom proizvodnjom definirana je Zakonom o obnovljivim izvorima energije i visokoučinkovitoj kogeneraciji [114–117] prema kojemu su opskrbljivači dužni preuzimati viškove električne energije od krajnjih kupaca s vlastitom proizvodnjom koji zadovoljavaju sljedeće uvjete:

- Krajnji kupac s vlastitom proizvodnjom ima status povlaštenog proizvođača električne energije;
- Ostvarili su pravo trajnog priključka na elektroenergetsku mrežu;
- Ukupna snaga svih proizvodnih postrojenja na jednom obračunskom mjernom mjestu ne prelazi 500 kW;
- Priključna snaga krajnjeg kupca s vlastitom proizvodnjom kao proizvođača ne prelazi priključnu snagu kao kupca;
- Kupac s vlastitom proizvodnjom isporučuje električnu energiju preko istog obračunskog mjernog mjesta preko kojeg i kupuje;
- Kupac s vlastitom proizvodnjom vodi podatke o proizvedenoj i isporučenoj električnoj energiji.

Prema [117], opskrbljivač plaća vrijednost preuzete električne energije od krajnjeg kupca s vlastitom proizvodnjom za obračunsko razdoblje koja se računa prema metodologiji prikazanoj u izrazu 5-1:

$$\begin{aligned} &\text{Ako vrijedi da je: } Ep_m \geq Ei_m \quad \longrightarrow \quad C_m = 0.9 \cdot PKC_m \\ &\text{Ako vrijedi da je: } Ep_m < Ei_m \quad \longrightarrow \quad C_m = 0.9 \cdot PKC_m \cdot \frac{Ep_m}{Ei_m} \end{aligned} \tag{5-1}$$

gdje su:

- C_m [kn/kWh] – vrijednost preuzete električne energije od krajnjeg kupca s vlastitom proizvodnjom unutar obračunskog razdoblja m,
- PKC_m [kn/kWh] – prosječna cijena električne energije koju kupac plaća opskrbljivaču za prodanu električnu energiju bez naknada za korištenje mreže i drugih naknada i poreza unutar obračunskog razdoblja m,
- Ep_m [kWh] – ukupna električna energija preuzeta iz mreže od strane kupca unutar obračunskog razdoblja m,
- Ei_m [kWh] – ukupna električna energija isporučena u mrežu od strane proizvodnog postrojenja u vlasništvu kupca, unutar obračunskog razdoblja m.

U simulacijskim slučajevima će se primijeniti dvotarifni sustav naplate električne energije (viša tarifa i niža tarifa) kao najkorišteniji način naplate električne energije u Republici Hrvatskoj, iako se korištena metodologija može primijeniti na tarifne sustave s j tarifa ili na sustav naplate s dinamičkim cijenama. Prema dvotarifnom modelu, u doba ljetnog računanja vremena viša tarifa (VT) je aktivna od 8 do 22 sata, a niža (NT) od 22 do 8 sati. U doba zimskog računanja vremena viša tarifa je aktivna od 7 do 21 sata, a niža od 21 do 7 sati. U simulacijskim slučajevima promatrat će se pogon mikromreže s ljetnim računanjem vremena. Trošak za preuzetu i predanu električnu energiju korišten u ovom modelu uzima u obzir pojedine tarifne stavke naplate.

Jedinični trošak za preuzetu električnu energiju od opskrbljivača $c_t^{\text{grid buy}}$ u vremenskom koraku t za testnu mikromrežu računa se prema izrazu 5-2. Sve tarifne stavke više tarife označene su indeksom $j = 1$, a niže tarife s indeksom $j = 2$.

$$c_t^{\text{grid buy}} = \left(c_j^{\text{energy buy}} + c_j^{\text{grid fee}} + c^{\text{RES fee}}\right) \cdot \left(1 + \frac{VAT}{100}\right) \quad \forall t \in T, j \in \mathbb{Z}, j \in [1,2] \tag{5-2}$$

gdje su:

$c_j^{\text{energy buy}}$ [kn/kWh] – naknada za preuzetu električnu energiju u tarifi j,
$c_j^{\text{grid fee}}$ [kn/kWh] – naknada za korištenje distribucijske i prijenosne mreže u tarifi j,
$c^{\text{RES fee}}$ [kn/kWh] – naknada za obnovljive izvore i visokoučinkovitu kogeneraciju,
VAT [%] – stopa poreza na dodanu vrijednost (PDV).

U tablici 5.1 prikazani su iznosi korištenih stavki prilikom izračuna jediničnog troška za preuzetu električnu energiju od opskrbljivača za referentni slučaj. Tarifne stavke za preuzetu električnu energiju u višoj i nižoj tarifi odgovaraju crvenom tarifnom modelu tvrtke HEP Elektra d.o.o. za kupce kategorije kućanstvo (za korisnike mreže s priključnom snagom većom od 20 kW) [118]. Iznosi naknade za korištenje distribucijske i prijenosne mreže definirani su Odlukom o iznosu tarifnih stavki za distribuciju električne energije [119] i Odlukom o iznosu tarifnih stavki za prijenos električne energije [120]. Stopa poreza na dodanu vrijednost od 13 % definirana je Zakonom o izmjenama i dopunama Zakona o porezu na dodanu vrijednost [121]. Prema gore navedenim tarifnim stavkama, jedinični trošak za preuzetu električnu energiju od opskrbljivača u višoj tarifi iznosi 0.9097 kn/kWh, a u nižoj tarifi 0.5029 kn/kWh.

Tablica 5.1: *Iznosi korištenih stavki za izračun jediničnog troška preuzete električne energije od opskrbljivača za referentni slučaj*

Stavka	**Iznos**
$c_1^{\text{energy buy}}$ [kn/kWh]	0.49
$c_2^{\text{energy buy}}$ [kn/kWh]	0.24
$c_1^{\text{grid fee}}$ [kn/kWh]	0.21
$c_2^{\text{grid fee}}$ [kn/kWh]	0.10
$c^{\text{RES fee}}$ [kn/kWh]	0.105
VAT [%]	13

Jedinična vrijednost predane električne energije opskrbljivaču $c_t^{\text{grid sell}}$ u vremenskom koraku t za testnu mikromrežu određuje se prema predstavljenoj metodologiji za aktivne kupce odnosno krajnje kupce s vlastitom proizvodnjom u izrazu 5-1, a računa se prema izrazu 5-3. Prihod od predane električne energije opskrbljivaču računa se na kraju promatranog obračunskog razdoblja (mjeseca) m i ovisi o preuzetoj električnoj energiji od opskrbljivača Ep_m i predanoj električnoj energiji opskrbljivaču Ei_m u obračunskom razdoblju m. Kako predložen sustav upravljanja energijom planira kratkoročni pogon mikromreže s horizontom planiranja od jednog dana, jedinična vrijednost predane električne energije opskrbljivaču koja ovisi o omjeru preuzete i predane električne energije na kraju obračunskog razdoblja ne

može se točno odrediti jer ima puno dulje vremensko razdoblje promatranja (mjesec dana). Stoga se za određivanje jedinične vrijednosti predane električne energije opskrbljivaču koriste povijesne vrijednosti preuzete i predane električne energije za isto obračunsko razdoblje n kao i promatrano obračunsko razdoblje m, ali u prošloj godini. Navedeno je pretpostavka u modelu jer vrijednosti preuzete električne energije od opskrbljivača i predane električne energije opskrbljivaču u promatranom obračunskom razdoblju m ne moraju biti jednake vrijednostima za isto obračunsko razdoblje u prošloj godini n. Treba zamijetiti da se prosječna jedinična cijena električne energije koju kupac plaća opskrbljivaču za prodanu električnu energiju PKC_m u izrazu 5-1 računa kao ponedirana aritmetička sredina, vidljivo u izrazu 5-3. To znači da prosječna jedinična cijena ovisi o udjelima preuzete električne energije po pojedinim tarifama.

$$\begin{aligned}
&\text{Ako je: } E_n^{\text{grid in}} \geq E_n^{\text{grid out}} \longrightarrow c_t^{\text{grid sell}} = 0.9 \cdot \frac{\sum_{j=1}^{J} \left(E_{n,j}^{\text{grid in}} \cdot c_j^{\text{energy buy}} \right)}{\sum_{j=1}^{J} E_{n,j}^{\text{grid in}}} \\
&\text{Ako je: } E_n^{\text{grid in}} < E_n^{\text{grid out}} \longrightarrow c_t^{\text{grid sell}} = 0.9 \cdot \frac{\sum_{j=1}^{J} \left(E_{n,j}^{\text{grid in}} \cdot c_j^{\text{energy buy}} \right)}{\sum_{j=1}^{J} E_{n,j}^{\text{grid in}}} \cdot \frac{E_n^{\text{grid in}}}{E_n^{\text{grid out}}}
\end{aligned} \tag{5-3}$$

gdje su:

$E_n^{\text{grid in}}$ [kWh] – preuzeta električna energija od opskrbljivača u obračunskom razdoblju n u prošloj godini,

$E_n^{\text{grid out}}$ [kWh] – predana električna energija opskrbljivaču u obračunskom razdoblju n u prošloj godini,

$c_t^{\text{grid sell}}$ [kn/kWh] – jedinična vrijednost predane električne energije opskrbljivaču u vremenskom koraku t,

$E_{n,j}^{\text{grid in}}$ [kWh] – preuzeta električna energija od opskrbljivača u obračunskom razdoblju n u tarifi j u prošloj godini,

$c_j^{\text{energy buy}}$ [kn/kWh] – naknada za preuzetu električnu energiju u tarifi j.

U simulacijskim slučajevima će se koristiti početna pretpostavka da je mikromreža u obračunskom razdoblju n preuzela više električne energije od opskrbljivača nego što ju je predala opskrbljivaču ($E_n^{\text{grid in}} \geq E_n^{\text{grid out}}$) što zadovoljava prvi uvjet u izrazu 5-3. Osim ovog omjera, na jediničnu cijenu prilikom predaje električne energije opskrbljivaču utječe i omjer preuzete električne energije po pojedinim tarifama. Kako se u testnoj mikromreži koristi dvotarifni sustav, kao početna pretpostavka koristi se omjer preuzete električne energije u višoj tarifi u odnosu na preuzetu električnu energiju u nižoj tarifi 80 : 20 % dok ukupna preuzeta električna energija $E_{n,j}^{\text{grid in}}$ u obračunskom razdoblju n za sve tarife j iznosi

32000 kWh. Spomenuti omjer i ukupna vrijednost rezultira da preuzeta električna energija $E_{n,j}^{\text{grid in}}$ od opskrbljivača u obračunskom razdoblju n u višoj tarifi iznosi 25600 kWh, dok u nižoj tarifi iznosi 6400 kWh. Prema gore definiranim vrijednostima, jedinična vrijednost predane električne energije opskrbljivaču iznosi 0.44 kn/kWh. Jedinični trošak/vrijednost preuzete/predane električne energije opskrbljivaču tijekom jednog dana grafički je prikazan na slici 5.2.

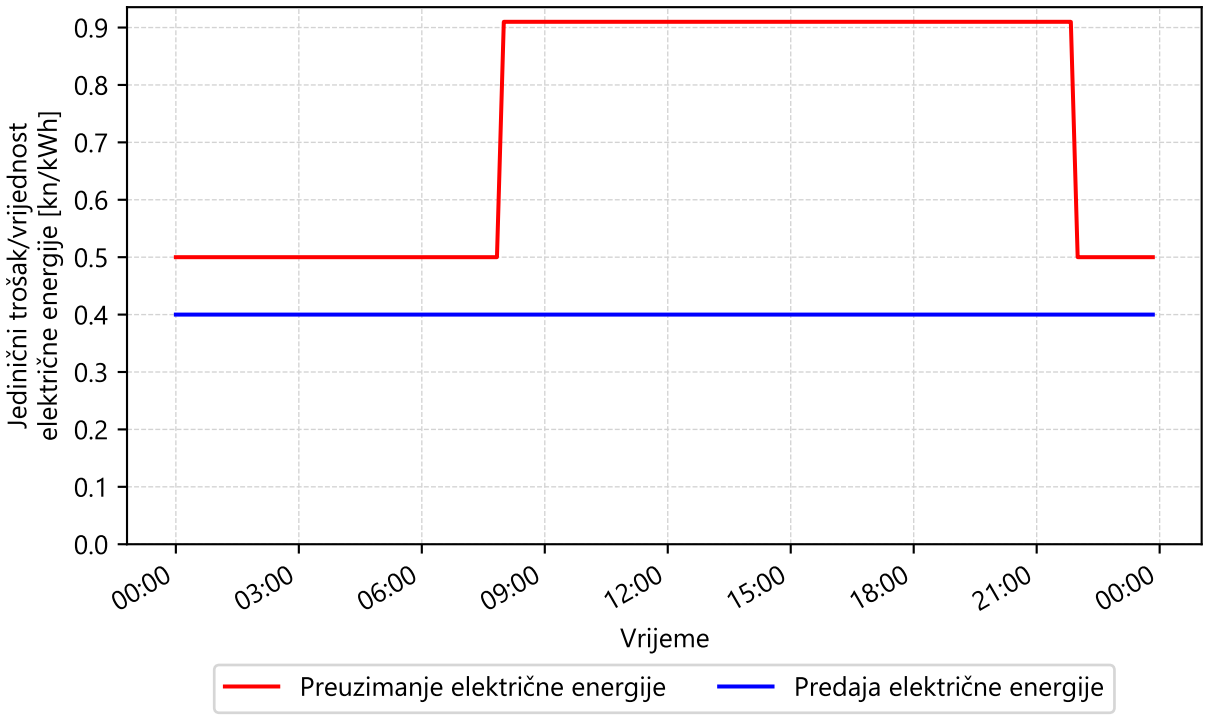

Slika 5.2: *Jedinični trošak/vrijednost preuzete/predane električne energije opskrbljivaču tijekom jednog dana za referentni slučaj*

Trošak novoangažirane snage definiran izrazom 4-8 ovisi o jediničnom trošku za angažiranu snagu $c^{\text{peak price}}$ i novoangažiranoj snazi $\Delta P^{\text{grid peak}}$ u trenutnom horizontu planiranja *SH*. Jedinični trošak za angažiranu snagu (obračunska vršna radna snaga) za kategoriju kupaca kućanstvo prema [122] iznosi 38.5 kn/kW i vrijedi za crveni tarifni model tvrtke HEP Elektra d.o.o. za korisnike mreže s priključnom snagom većom od 20 kW [123]. U referentnom slučaju koristi se pretpostavka povijesne vrijednosti najveće angažirane snage $P_m^{\text{grid peak}}$ u tekućem obračunskom razdoblju m od 70.2 kW. Vrijednost od 70.2 kW predstavlja najveću angažiranu snagu do dana u mjesecu (obračunskom razdoblju) za koji se vrši kratkoročno planiranje pogona.

Priključna snaga testne mikromreže za referentni slučaj u smjeru preuzimanja električne energije iz nadređene elektroenergetske mreže ($P^{\text{grid in max}}$) iznosi 400 kW, dok u smjeru predaje u elektroenergetsku mrežu ($P^{\text{grid out max}}$) također iznosi 400 kW (zbroj snaga svih proizvodnih postrojenja krajnjeg kupca). Prema mrežnim pravilima distribucijskog

sustava [112], na niskonaponski vod priključuje se postrojenje i instalacija pojedinačnog proizvođača (vrijedi i za kupce s vlastitom proizvodnjom) priključne snage do uključivo 100 kW dok se za priključne snage iznad 100 kW, a manje od uključivo 500 kW, postrojenje i instalacija pojedinačnog proizvođača (krajnjeg kupca s vlastitom proizvodnjom) priključuje na niskonaponske sabirnice u transformatorskoj stanici (TS) 10(20)/0.4 kV. Postrojenje i instalacija pojedinačnih proizvođača s priključnom snagom do uključivo 20 MW se priključuju na srednjenaponsku mrežu. Testna mikromreža zbog gore definiranih uvjeta će se priključiti na niskonaponske sabirnice u transformatorskoj stanici modela elektroenergetske mreže u koju se mikromreža integrira.

Mrežna pravila distribucijskog sustava [112] definiraju i uvjete faktora snage krajnjeg kupca s vlastitom proizvodnjom na mjestu priključka u svrhu podrške održavanja napona jalovom snagom. Postrojenje i instalacija proizvođača (kupca s vlastitom proizvodnjom) moraju imati mogućnost pogona s faktorom snage 0.9 induktivno (poduzbuđeno) do 0.9 kapacitivno (naduzbuđeno), što će se također primijeniti na testnu mikromrežu u obliku varijabli nižeg sloja sustava upravljanja enegijom $\varphi_{\text{ind}}^{\text{PCC}} = 0.9$ i $\varphi_{\text{cap}}^{\text{PCC}} = 0.9$.

Napon na čvorovima (sabirnicama) mikromreže $V_{k,bus}$ tijekom kratkoročnog planiranja pogona ne smije biti niži od 90 % iznosa nazivnog napona ($V_{bus}^{\min}$) i ne smije biti viši od 110 % vrijednosti nazivnog napona ($V_{bus}^{\max}$).

Radi bolje preglednosti, u tablici 5.2 se nalaze svi parametri korišteni u simulacijama prilikom modeliranja elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu) za referentni slučaj.

Tablica 5.2: *Iznosi parametara modela mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu) za referentni slučaj*

Parametar	**Iznos**
$c_t^{\text{grid buy}}$ (VT) [kn/kWh]	0.9097
$c_t^{\text{grid buy}}$ (NT) [kn/kWh]	0.5029
$c_t^{\text{grid sell}}$ [kn/kWh]	0.44
$c^{\text{peak price}}$ [kn/kW]	38.5
$P^{\text{grid in max}}$ [kW]	400
$P^{\text{grid out max}}$ [kW]	400
$P_m^{\text{grid peak}}$ [kW]	70.2
$\varphi_{\text{ind}}^{\text{PCC}}$	0.9
$\varphi_{\text{cap}}^{\text{PCC}}$	0.9

5.2.2. Model testne mikromreže u *IEEE European Low Voltage Test Feeder* testnom sustavu za referentni slučaj

Testna mikromreža integrira se u niskonaponski testni sustav *IEEE European Low Voltage Test Feeder* naponskih razina 11/0.416 kV s nesimetričnim opterećenjem po fazama. Mreža predstavlja tipični europski niskonaponski izvod s linijskim naponom od 416 V i frekvencijom od 50 Hz. Niskonaponski testni izvod sastoji se od jednog transformatora s prijenosnim omjerom 11/0.416 kV, 907 sabirnica (čvorova), 905 vodova i 55 potrošača (kupaca) predstavljenih s 55 profila opterećenja (potrošnje električne energije) s rezolucijom od 1 minute kroz 24 sata (1 dan). Jednofazna shema testnog izvoda vidljiva je na slici 5.3 na kojoj su brojevima označena trošila (kupci). Ovo omogućuje izvođenje simulacija pogona izvoda u vremenu od jednog dana. Niskonaponska mreža se spaja na 11 kV srednjenaponsku mrežu preko 11/0.416 kV transformatora nazivne prividne snage 0.8 MVA, sa spojem namota trokut-uzemljena zvijezda (Dyn). Referentni čvor u mreži regulira napon na iznos od 1 p.u. dok početna snaga trofaznog kratkog spoja iznosi 3 MVA, a jednofaznog kratkog spoja 2 MVA. Više o testnom sustavu može se pronaći u dokumentaciji [124].

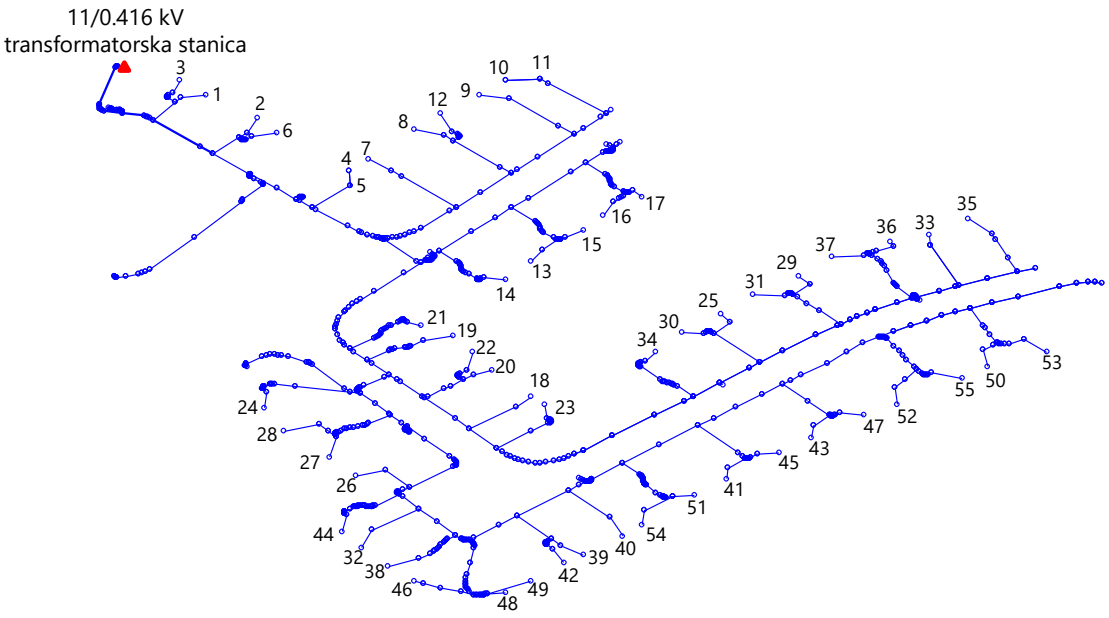

Slika 5.3: *Jednofazna shema testnog sustava IEEE European Low Voltage Test Feeder*

Testni izvod se koristi samo u nižem sloju sustava upravljanja energijom koji sadržava model testne mikromreže razvijen u simulacijskom alatu za modeliranje i analizu elektroenergetskih mreža *OpenDSS*. Viši sloj sustava upravljanja energijom modelira mikromrežu kao jednosabirnički sustav kod kojeg se smatra da su svi elementi mikromreže spojeni na jednu sabirnicu, promatraju se samo tokovi radne snage, a električka ograničenja mikromreže se zanemaruju. Jednofazna shema testne mikromreže u simulacijskom alatu za modelira-

nje i analizu elektroenergetskih mreža *OpenDSS* vidljiva je na slici 5.4. Shema prikazuje nazive sabirnica te nazive i tipove korištenih kabela unutar testne mikromreže. Radi bolje preglednosti, na jednofaznoj shemi je prikazan samo prvi potrošač (kupac) od ukupno njih 55 u testnom izvodu. Testna mikromreža je spojena na nadređenu elektroenergetsku mrežu (PCC oznaka na slici 5.4) na niskonaponske sabirnice u transformatorskoj stanici 11/0.416 kV. Dodatna električka ograničenja koja optimizacijski problem nižeg sloja sustava upravljanja energijom implementira opisana u poglavlju 4.7.1 primjenjuju se samo na elemente mikromreže odnosno do mjesta razgraničenja s ostatkom distribucijske mreže.

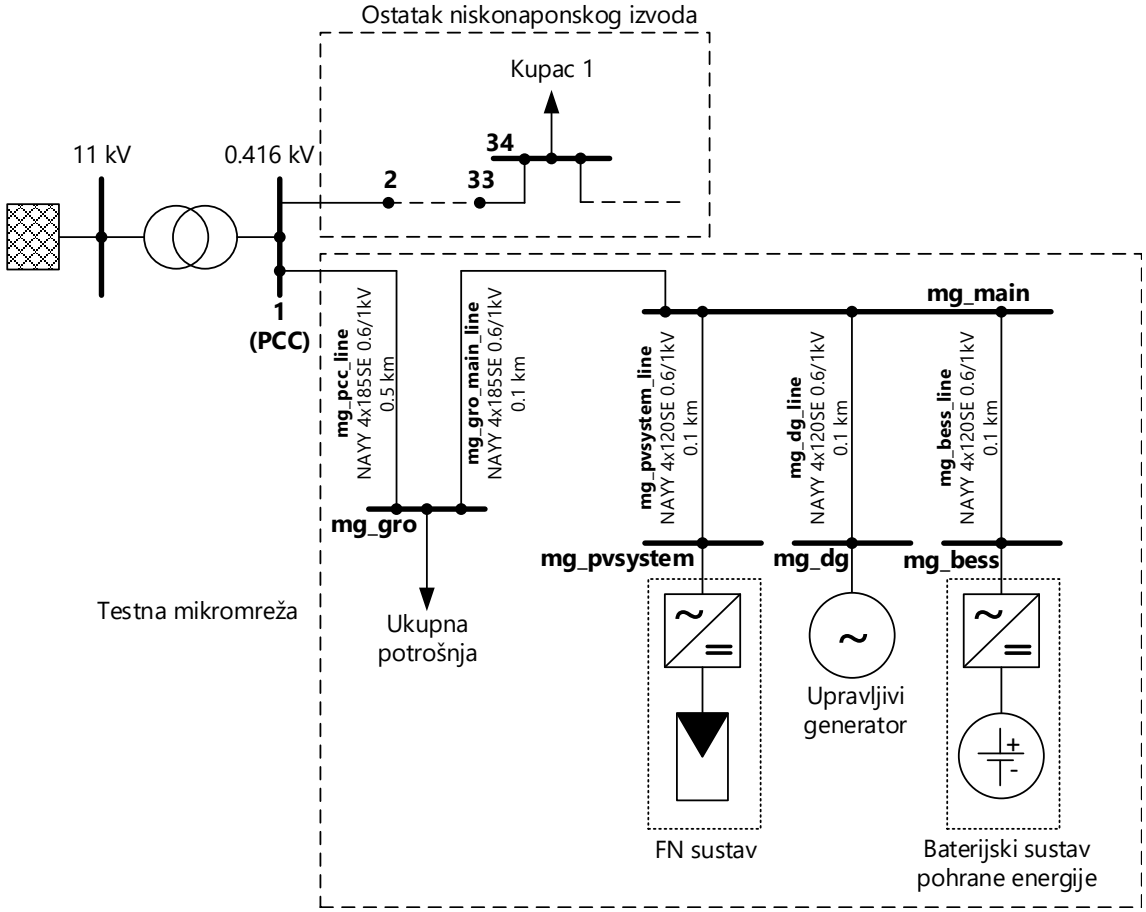

Slika 5.4: *Jednofazna shema testne mikromreže integrirane u testni sustav IEEE European Low Voltage Test Feeder za referentni slučaj*

5.2.3. Tehničke karakteristike baterijskog sustava pohrane energije za referentni slučaj

U referentnom slučaju modelira se jedan baterijski sustav pohrane energije (indeks $BESS = 1$) s nazivnom izmjeničnom snagom dvosmjernog pretvarača energetske elektronike P_1^{nom} od 50 kW i energetskim kapacitetom baterije E_1^{cap} od 200 kWh.

Podaci o učinkovitosti dvosmjernog pretvarača energetske elektronike dobiveni su eksperimentalnim mjerenjem učinkovitosti dvosmjernog pretvarača energetske elektronike Victron

Energy Multiplus C 24/800/16 nazivne prividne snage 800 VA u Laboratoriju za obnovljive izvore energije FERIT-a Osijek čije su tehničke karakteristike dostupne u [125]. Karakteristika učinkovitosti pretvarača formirana je pomoću 22 mjerne točke za različita opterećenja izražena u odnosu na nazivnu snagu pretvarača (p.u. vrijednosti). Nelinearna karakteristika je linearizirana pomoću tehnike linearizacije funkcije s 4 linearna odsječka u višem programskom jeziku *Python* pomoću paketa *pwlf* metodom najmanjih kvadrata. Nelinearna karakteristika učinkovitosti i njena linearna aproksimacija vidljive su na slici 5.5. Koordinate točaka linearne aproksimacije prikazane su u tablici 5.3 i kao takve će se koristiti u optimizacijskim problemima pojedinih slojeva sustava upravljanja energijom. Na slici 5.5 vidljivo je kako se linearnom aproksimacijom s 4 linearna odsječka ostvaruju zadovoljavajući rezultati aproksimacije nelinearne karakteristike. Smanjenjem broja odsječaka ostvaruju se lošiji rezultati, dok se povećanjem dobivaju bolji rezultati, ali se povećava i računalna složenost optimizacijskih modela koja se želi izbjeći.

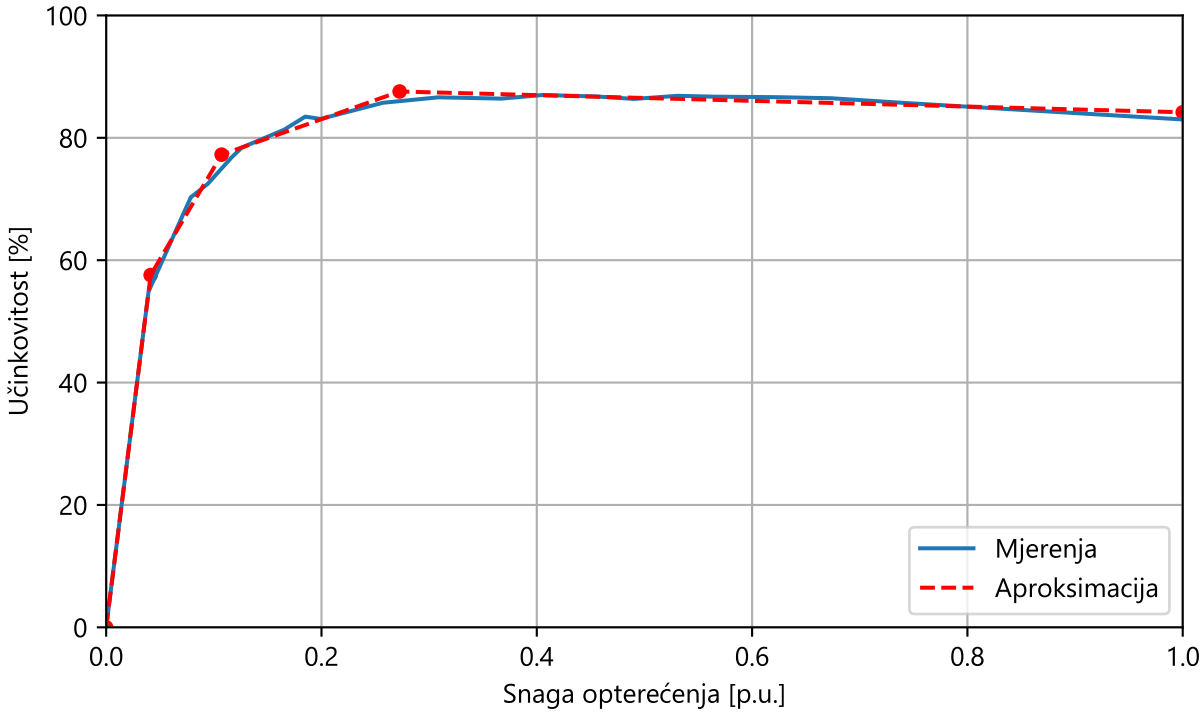

Slika 5.5: *Linearna aproksimacija učinkovitosti dvosmjernog pretvarača energetske elektronike Victron MultiPlus C 24/800/16 korištena za referentni slučaj*

Tablica 5.3: *Koordinate točaka linearne aproksimacije nelinearne karakteristike učinkovitosti dvosmjernog pretvarača energetske elektronike za referentni slučaj*

Snaga opterećenja [p.u.]	**Učinkovitost [%]**
0	0
0.041312	57.57
0.10723	77.25
0.27257	87.57
1	84.17

Dvosmjernom pretvaraču energetske elektronike pridružuje se baterija energetskog kapaciteta $E_1^{\text{cap}} = 200$ kWh s maksimalno dozvoljenom snagom pražnjenja $P_1^{\text{disch max batt}}$ od 50 kW. Maksimalna dopuštena snaga punjenja baterije se modelira pomoću energetskog modela punjenja opisanog u poglavlju 4.2.2. Prema energetskom modelu punjenja, snaga punjenja ovisi o energiji koju baterija može apsorbirati ΔSOE, a koja ovisi o trenutnom stanju napunjenosti baterije SOE. Nelinearna $\Delta SOE/SOE$ karakteristika potrebna za implementaciju ovog modela dobivena je eksperimentalnim mjerenjima procesa punjenja litij-ionskog baterijskog članka tipa 18650 *Sony US18650VTC5*. Karakteristika je snimana pomoću *Junsi iCharger 4010 Duo* uređaja za punjenje/pražnjenje u Laboratoriju za obnovljive izvore energije FERIT-a Osijek. Kapacitet baterijskog članka *Sony US18650VTC5* iznosi 2500 mAh, maksimalna struja punjenja 2.5 A (faktor 1C), a maksimalna struja pražnjenja 20 A (8C). Nelinearna karakteristika $\Delta SOE/SOE$ generirana je iz mjernih podataka za proces punjenja s maksimalno dozvoljenom strujom punjenja od 2.5 A (1C) nakon čega je linearizirana pomoću tehnike linearizacije funkcije s 3 linearna odsječka u višem programskom jeziku *Python* pomoću paketa *pwlf* metodom najmanjih kvadrata. Nelinearna karakteristika $\Delta SOE/SOE$ i njena linearna aproksimacija vidljive su na slici 5.6. Treba zamijetiti da je veličina ΔSOE na slici 5.6 izražena u p.u. vrijednostima u odnosu na maksimalnu energiju koju je baterijski članak apsorbirao tijekom procesa punjenja, a koja je rezultat umnoška napona i maksimalne struje punjenja (2.5 A, faktor 1C) i vremena. Ovaj pristup koristi se kako bi se model generalizirao i mogao primijeniti na baterije različitih tehničkih karakteristika. Koordinate točaka nakon linearne aproksimacije nelinearne karakteristike prikazane su u tablici 5.4 i kao takve će se koristiti u optimizacijskim problemima pojedinih slojeva sustava upravljanja energijom za referentni slučaj. Na slici 5.5 vidi se kako se linearnom aproksimacijom s 3 linearna odsječka ostvaruju zadovoljavajući rezultati aproksimacije nelinearne karakteristike. Kao i kod slučaja s aproksimacijom učinkovitosti dvosmjernog pretvarača energetske elektronike, smanjenjem broja odsječaka ostvaruju se lošiji rezultati, dok se povećanjem dobivaju bolji rezultati, ali se povećava i računalna složenost optimizacijskih

modela što se želi izbjeći.

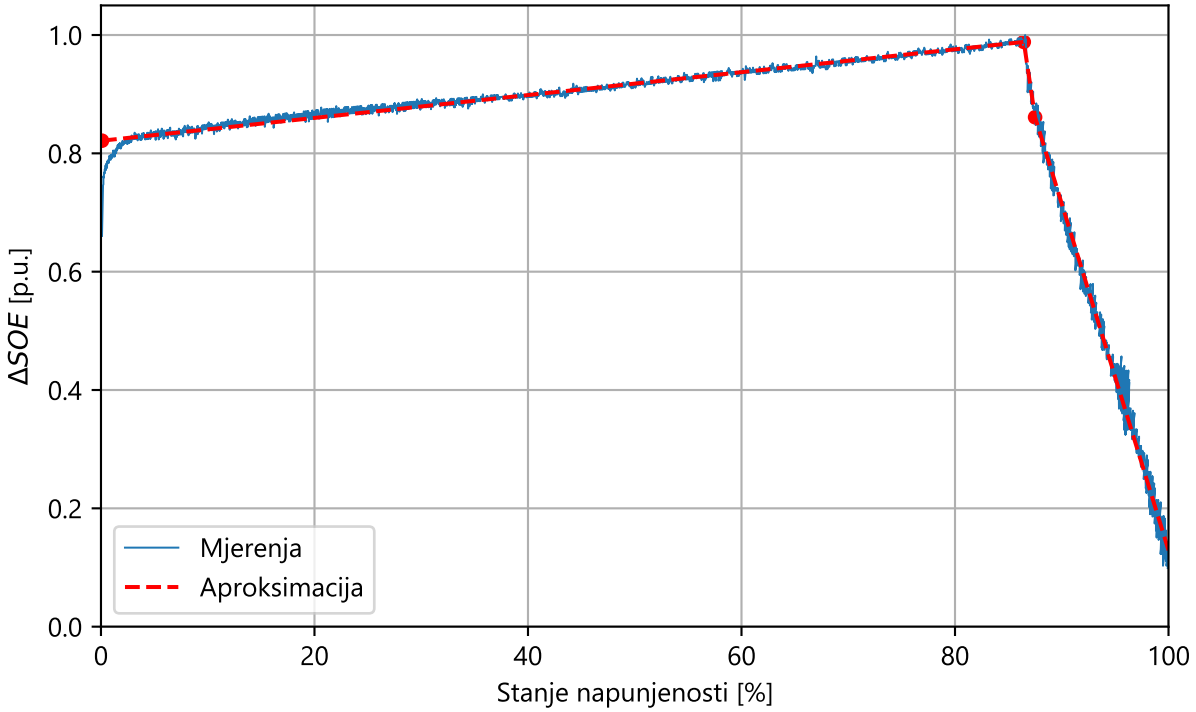

Slika 5.6: *Linearna aproksimacija karakteristike $\Delta SOE/SOE$ prilikom procesa punjenja litij-ionskog baterijskog članka Sony US18650VTC5 pri faktoru 1C korištena za referentni slučaj*

Tablica 5.4: *Koordinate točaka linearne aproksimacije nelinearne karakteristike $\Delta SOE/SOE$ za referentni slučaj*

Stanje napunjenosti *SOE* [%]	***ΔSOE* [p.u.]**
0.0955711	0.75449
2.13553	0.828992
85.5974	0.984584
100	0.125893

Energetska učinkovitost η^{E} također se odredila eksperimentalnim mjerenjima prema izrazu 4-15. Iznos energetske učinkovitosti od 86 % dobiven je nakon procesa potpunog punjenja i pražnjenja litij-ionskog baterijskog članka *Sony US18650VTC5* pri jednakim faktorima (faktor 1C) pomoću *Junsi iCharger 4010 Duo* uređaja za punjenje/pražnjenje u Laboratoriju za obnovljive izvore energije FERIT-a Osijek.

Stanje napunjenosti baterijskog sustava pohrane energije $SOE_{t,1}^{\%}$ u bilo kojem vremenskom koraku je ograničeno minimalnom ($SOE_1^{\min}$) i maksimalnom razinom ($SOE_1^{\max}$) tijekom horizonta planiranja koje iznose 0 % (minimalno) i 100 % (maksimalno) definirano izrazima 4-19 i 4-20. Stanje napunjenosti baterije na početku horizonta planiranja $SOE_{0,1}^{\%}$

(vremenski korak 0) ovisi o početnom stanju sustava IS_i odnosno iteraciji optimizacije i, vidljivo i na slici 3.1. U prvoj iteraciji optimizacijskog postupka ($i = 0$) početno stanje napunjenosti definira se prema izrazu 4-21 i iznosi 100 %. Stanje napunjenosti u svim višim iteracijama ($i = 1, 2, 3, ...$) ovisi o stanju napunjenosti na kraju prošle iteracije.

Prilikom modeliranja cikličkog odnosno kalendarskog starenja baterijskog sustava pohrane energije, opisano u poglavlju 4.2.3, u funkciju cilja optimizacijskog problema višeg sloja sustava upravljanja energijom uvrštavaju se dodatni (virtualni) troškovi. Dodatni (virtualni) troškovi ovise o životnom vijeku baterijskog sustava pohrane energije T_1^{lifetime} za koji se uzima vrijeme od 15 godina (izraženo brojem vremenskih koraka optimizacijskog problema) i trošku zamjene (investicijski trošak) baterijskog sustava pohrane energije $c_1^{\text{replace cost}}$. Trošak zamjene se definira prema izrazu 4-25, a ovisi o investicijskom trošku baterije izražen po kWh energetskog kapaciteta $c^{\text{price kWh}}$, investicijskom trošku dvosmjernog pretvarača energetske elektronike izražen po kW instalirane snage $c^{\text{price kW}}$ i trajanju korištenja baterijskog sustava pohrane energije T_1^{duration}, definiranog u izrazu 4-26. Trajanje korištenja baterijskog sustava pohrane energije iznosi 4 sata ($T_1^{\text{duration}} = 200/50 = 4\text{h}$). Za investicijski trošak baterije uzima se iznos od 300 \$/kWh što konvertirano iznosu 1900.21 kn/kWh (za konverziju je korišten srednji tečaj USD za devize Hrvatske narodne banke (HNB) na dan 1. rujna 2021. od 6.334042 kn/\$) prema [95]. Za investicijski trošak dvosmjernog pretvarača energetske elektronike koristi se iznos od 260 \$/kW što konvertirano iznosi 1646.85 kn/kW prema [95].

Trošak kalendarskog starenja definiran izrazom 4-24 ovisi i o koeficijentima linearizirane karakteristike faktora stresa kalendarskog starenja (izraz 4-23) koji iznose $k_0^{\text{cal}} = 0.3$, a $k^{\text{cal}} = 1.7$, prema [94]. Trošak cikličkog starenja definiran izrazom 4-32 ovisi o nelinearnoj funkciji gubitka životnog vijeka baterije uslijed ciklusa s određenim pražnjenjem definiran izrazom 4-33. Za uvrštavanje nelinearne karakteristike u linearni optimizacijski problem potrebno je izvršiti aproksimaciju tehnikom linearizacije pomoću više linearnih odsječaka. Nelinearna karakteristika je linearno aproksimirana s 4 odsječka (slika 4.9) u višem programskom jeziku *Python* pomoću paketa *pwlf* metodom najmanjih kvadrata. Koordinate točaka linearne aproksimacije prikazane su u tablici 5.5 i kao takve će se koristiti u optimizacijskim problemima pojedinih slojeva sustava upravljanja energijom za referentni slučaj.

Tablica 5.5: *Koordinate točaka linearne aproksimacije nelinearne funkcije gubitka životnog vijeka uslijed cikličkog starenja za referentni slučaj*

Gubitak životnog vijeka baterije [p.u.]	**Dubina pražnjenja ciklusa [%]**
0	0
$2.90606 \cdot 10^{-5}$	26.28
0.000119081	49.43
0.000288485	75.42
0.000519076	100

Kod modeliranja dodatnog (virtualnog) prihoda koji valorizira pohranjenu energiju opisanog u poglavlju 4.2.4, za parametar J, koji predstavlja vrijeme potrebno da se baterija potpuno isprazni pri nazivnoj izmjeničnoj snazi dvosmjernog pretvarača energetske elektronike (trajanje korištenja definirano izrazom 4-26), se uzima da iznosi $J_1 = T_1^{\text{duration}} = 200/50 = 4$ h izražen kao broj vremenskih koraka optimizacijskog problema višeg sloja.

Radi bolje preglednosti, u tablici 5.6 nalaze se svi parametri korišteni u simulacijama prilikom modeliranja baterijskog sustava pohrane energije za referentni slučaj.

Tablica 5.6: *Iznosi parametara modela baterijskog sustava pohrane energije za referentni slučaj*

Parametar	**Iznos**
P_1^{nom} [kW]	50
E_1^{cap} [kWh]	200
$P_1^{\text{disch max batt}}$ [kW]	50
η^{E} [%]	86
SOE_1^{min} [%]	0
SOE_1^{max} [%]	100
$SOE_{0,1}^{\%}$ [%]	100
T_1^{lifetime} [god.]	15
T_1^{duration} [h]	4
$c^{\text{price kWh}}$ [kn/kWh]	1900.21
$c^{\text{price kW}}$ [kn/kWh]	1646.85

5.2.4. Tehničke karakteristike fotonaponskog sustava za referentni slučaj

U referentnom slučaju se modelira jedan fotonaponski sustav (indeks $PV = 1$) s nazivnom izmjeničnom snagom izmjenjivača $P_1^{\text{inv nom}}$ od 150 kW. Snaga fotonaponskog polja pri standardnim testnim uvjetima $P_1^{\text{array STC}}$ iznosi 150.4 kW, a sastoji se od 470 fotonaponska

modula snage 320 W. Podaci o temperaturnom koeficijentu snage γ_1 i nominalna radna temperatura ćelija $NOCT_1$ preuzeti su iz tehničkih specifikacija fotonaponskog modula izrađenog od monokristalnog silicija *Luxor ECO LINE LX-320M/158-60+* nazivne snage 320 W [126] i iznose 0.4 %/°C i 45 °C. Za izmjenjivač fotonaponskog sustava koriste se tehničke karakteristike izmjenjivača *SMA Sunny Highpower Peak3 SHP 150-20* nazivne izmjenične snage 150 kVA dostupne u [127]. Karakteristika učinkovitosti izmjenjivača koja se koristi u optimizacijskim modelima ovisna je o opterećenju pretvarača i generirana je prema rezultatima mjerenja proizvođača za 8 točaka (prema normi DIN EN 50524:2010) [128], prikazanih u tablici 5.7. Iako se mjerne točke učinkovitosti izmjenjivača za različita opterećenja mogu uvrstiti u optimizacijski problem u izvornom obliku prikazanom u tablici 5.7, karakteristika učinkovitosti će se linearno aproksimirati s 3 linearna odsječka kako bi se smanjila računalna složenost optimizacijskog modela. Linearna aproksimacija je izvršena u višem programskom jeziku *Python* pomoću paketa *pwlf* metodom najmanjih kvadrata. Koordinate točaka nakon linearne aproksimacije nelinearne karakteristike prikazane su u tablici 5.8 i kao takve će se koristiti u optimizacijskim problemima pojedinih slojeva sustava upravljanja energijom za referentni slučaj. Prikaz originalne karakteristike i njene linearne aproksimacije s 3 linearna odsječka vidljiv je na slici 5.7.

Tablica 5.7: *Učinkovitost izmjenjivača SMA Sunny Highpower Peak3 SHP 150-20 za različita opterećenja pretvarača*

Snaga opterećenja [p.u.]	**Učinkovitost [%]**
0.05	97.1
0.1	98.3
0.2	98.9
0.25	98.9
0.3	99
0.5	98.1
0.75	98.8
1	98.5

Tablica 5.8: *Koordinate točaka linearne aproksimacije nelinearne karakteristike učinkovitosti izmjenjivača fotonaponskog sustava za referentni slučaj*

Snaga opterećenja [p.u.]	**Učinkovitost [%]**
0	0
0.0140175	96.24
0.124262	98.88
1	98.46

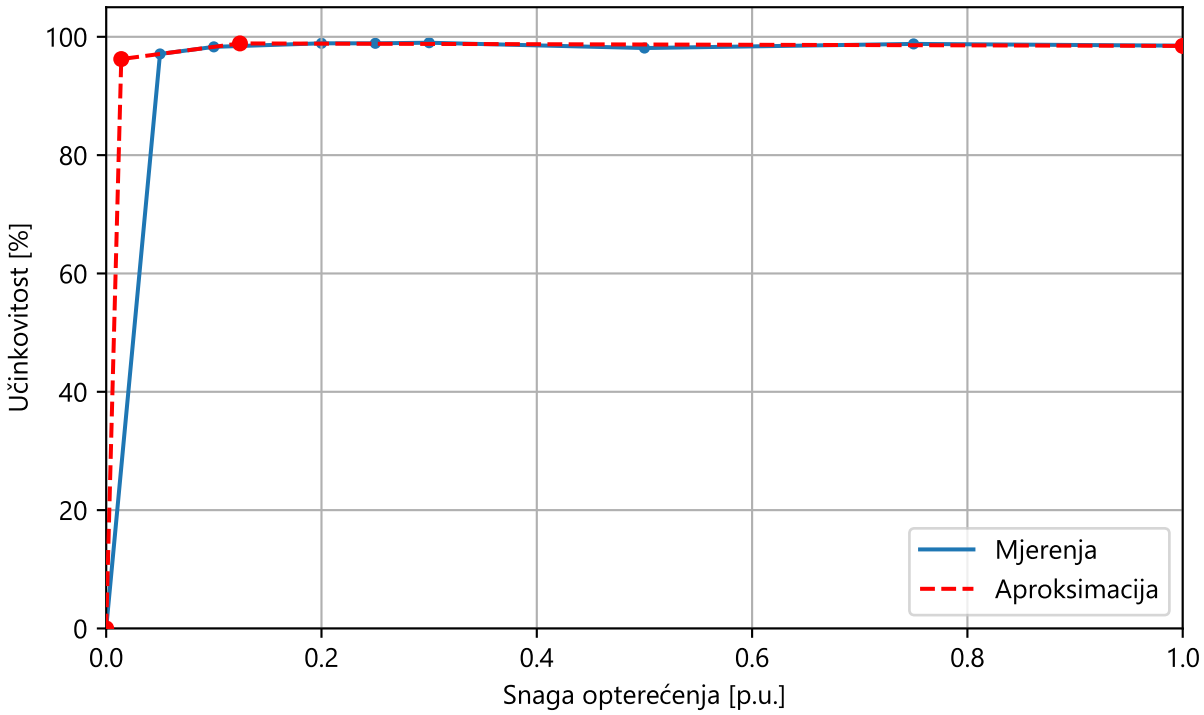

Slika 5.7: *Linearna aproksimacija nelinearne karakteristike učinkovitosti izmjenjivača SMA Sunny Highpower Peak3 SHP 150-20 pri različitim opterećenjima korištena za referentni slučaj*

Radi bolje preglednosti, u tablici 5.9 se nalaze svi parametri korišteni u simulacijama prilikom modeliranja baterijskog sustava pohrane energije za referentni slučaj.

Tablica 5.9: *Iznosi parametara modela fotonaponskog sustava za referentni slučaj*

Parametar	**Iznos**
$P_1^{\text{inv nom}}$ [kW]	150
$P_1^{\text{array STC}}$ [kW]	150.4
γ_1 [%/°C]	0.4
$NOCT_1$ [°C]	45

5.2.5. Tehničke karakteristike upravljivog generatora

Za referentni slučaj se modelira jedan upravljivi generator (indeks $DG = 1$) tipa dizel agregata nazivne radne snage od 200 kW odnosno nazivne prividne snage 250 kVA i nazivnog faktora snage 0.8 (induktivno) kao dodatnog izvora električne energije posebice u slučaju izoliranog (otočnog) pogona testne mikromreže. Tehničke karakteristike su preuzete za dizelski agregat *Himoinsa HFW-245 T5* [129]. Kako je model upravljivog generatora, opisan u poglavlju 4.4, koncipiran da omogućuje modeliranje jedinica s različitim instaliranim snagama, ovisno o veličini mikromreže, kod manjih jedinica (kao što se modelira za testnu mikromrežu), određena ograničenja se mogu zanemariti.

Izlazna snaga upravljivog generatora $P_{t,1}^{\mathrm{DG}}$ definirana izrazom 4-39 nema donje ograničenje ($P_{dg}^{\mathrm{DG\ min}} = 0$ kW), nego se ograničava samo s maksimalnom izlaznom snagom $P_{1}^{\mathrm{DG\ max}}$ koja je jednaka instaliranoj snazi od 200 kW. Promatrani dizelski agregat nema ograničenje promjene izlazne snage pa se ograničenja definirana izrazima 4-40 i 4-41 zanemaruju. Isto se primjenjuje za ograničenja minimalnog vremena proizvodnje definiranog izrazom 4-42 i minimalnog vremena prestanka proizvodnje definiranog izrazom 4-43.

Ukupni trošak rada upravljivog generatora definiran je izrazom 4-46 i ovisi o trošku pokretanja i trošku za gorivo. U ovom slučaju se trošak pokretanja definiran izrazom 4-47 zanemaruje, dok trošak za gorivo definiran izrazom 4-48 ovisi o izlaznoj snazi upravljivog generatora. Podaci o potrošnji goriva za različite izlazne snage preuzete su iz tehničkih specifikacija promatranog dizelskog agregata i prikazani su u tablici 5.10 [129].

Tablica 5.10: *Potrošnja goriva dizelskog agregata za različite izlazne snage*

Izlazna snaga [p.u.]	**Potrošnja [L/h]**
0	0
0.25	14.4
0.5	25.7
0.8	41.3
1	52.4

Kako model upravljivog generatora zahtijeva trošak goriva (vidljivo u izrazima 4-48 i 4-49), izračunat će se jedinični trošak goriva ovisan o izlaznoj snazi pomoću prosječne cijene eurodizelskog goriva na dan 6. rujna 2021. preuzete od udruge Hrvatski autoklub (HAK) od 10.50 kn/L [130] i podataka o potrošnji goriva prikazanim u tablici 5.10. Trošak goriva i jedinični trošak goriva promatranog dizelskog agregata za referentni slučaj prikazan je tablično u 5.11 i grafički na slici 5.8. Treba primijetiti da trošak goriva promatranog agregata nije zadan u obliku kvadratne funkcije, nego u obliku 5 točaka s različitom izlaznom snagom

i pripadajućom potrošnjom pri toj snazi pomoću kojih se može generirati karakteristika troška goriva s više linearnih odsječaka. Ovo omogućuje izravno korištenje karakteristike u optimizacijskim problemima budući da nije potreban postupak linearne aproksimacije.

Tablica 5.11: *Trošak goriva i jedinični trošak goriva upravljivog generatora za različite izlazne snage za referentni slučaj*

Izlazna snaga [p.u.]	Izlazna snaga [kW]	Trošak goriva [kn/h]	Jedinični trošak goriva [kn/kWh]
0	0	0	0
0.25	50	151.2	3.02
0.5	100	269.85	2.7
0.8	150	433.65	2.71
1	200	550.2	2.75

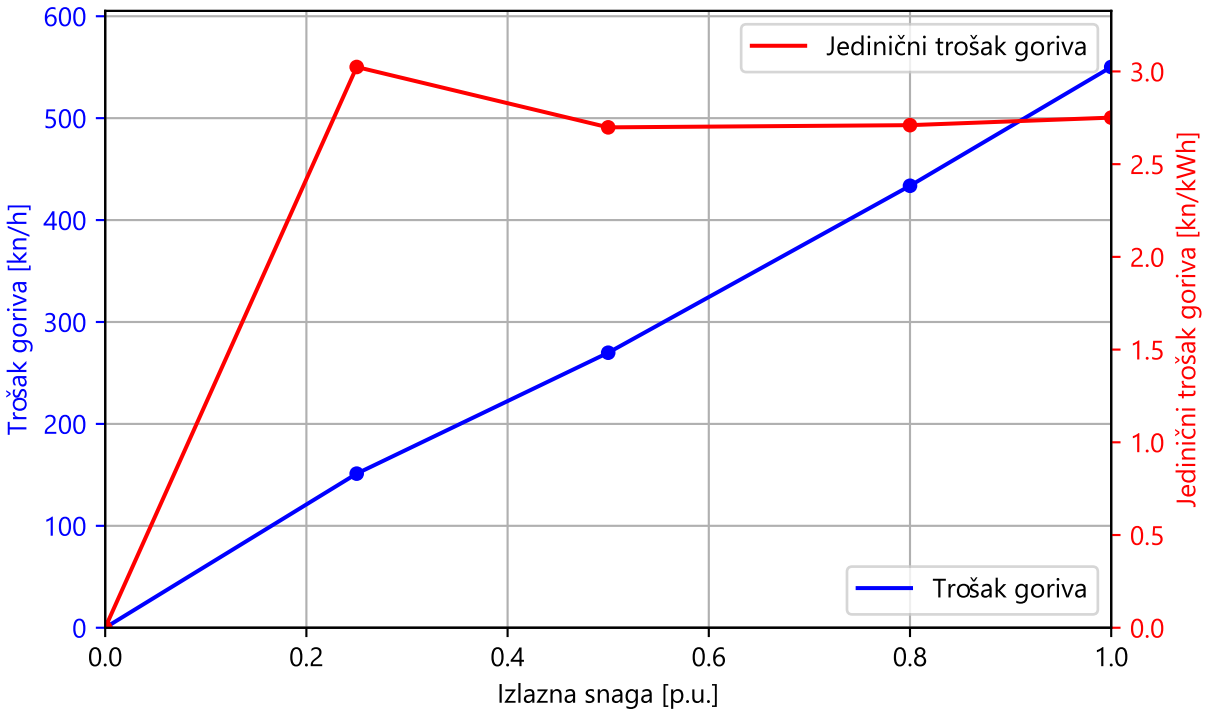

Slika 5.8: *Trošak goriva i jedinični trošak goriva upravljivog generatora za različite izlazne snage za referentni slučaj*

Radi bolje preglednosti, u tablici 5.12 nalaze se svi parametri korišteni u simulacijama prilikom modeliranja upravljivog generatora za referentni slučaj.

Tablica 5.12: *Iznosi parametara modela upravljivog generatora za referentni slučaj*

Parametar	Iznos
$P_1^{\text{DG min}}$ [kW]	0
$P_1^{\text{DG max}}$ [kW]	200

5.2.6. Tehničke karakteristike trošila električne energije za referentni slučaj

Trošila električne energije testne mikromreže dijele se na neupravljiva (kritična) i upravljiva trošila. Za neupravljivu (kritičnu) potrošnju električne energije koriste se podaci o 10-minutnim srednjim vrijednostima potrošnje zgrade FERIT Osijek na adresi Kneza Trpimira 2B, 31000 Osijek za razdoblje od 6. ožujka 2017. do 8. svibnja 2019. godine. Podaci su preuzeti iz *online* baze podataka Laboratorija za obnovljive izvore energije FERIT-a Osijek [131]. Podaci o potrošnji ne koriste se izravno kao ulazni podaci u simulacijske slučajeve, nego se koriste za treniranje umjetnih neuronski mreža, opisanih u poglavlju 4.8.1, potrebne za predviđanje potrošnje električne energije testne mikromreže. Profil snage neupravljive potrošnje vidljiv je na slici 5.9.

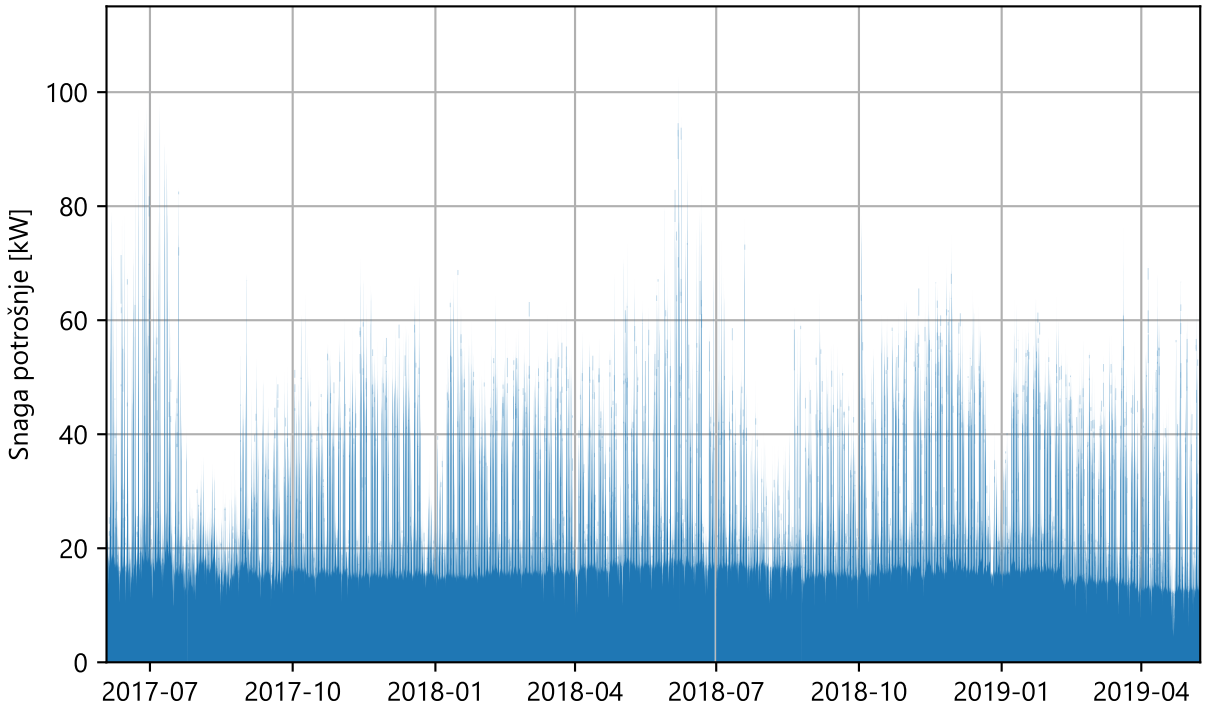

Slika 5.9: *Profil izmjerene snage neupravljive potrošnje testne mikromreže*

Za referentni slučaj modelira se jedno statički upravljivo trošilo prema modelu opisanom u poglavlju 4.5.1. Trošilo predstavlja klimatizacijski sustav s 5 jedinica pojedinačne snage 4.87 kW (ukupno 24.35 kW) instaliran u zgradi FERIT-a Osijek. Kako bi se što realnije modeliralo statički upravljivo trošilo u obliku klimatizacijskog sustava s 5 jedinica,

na slici 5.10 je napravljena usporedba profila jednog ciklusa potrošnje promatranog klimatizacijskog sustava izmjerenog 4. srpnja 2018. godine u razdoblju od 8:00 sati do 9:40 sati i modeliranog profila potrošnje. Prikazana mjerenja potrošnje predstavljaju 10-minutne srednje vrijednosti snage za jedan ciklus rada klimatizacijskog sustava. Profil snage potrošnje statičkog upravljivog trošila prikazanog na slici 5.10 modeliran je na način da što bolje prati stvarni profil potrošnje klimatizacijskog sustava uključenjem odnosno isključenjem pojedinih jedinica i kao takav će se koristiti u simulacijskim slučajevima uz ponavljanje dva puta u danu. Prvi put ciklus potrošnje započinje u 11:00 sati, a drugi u 14:00 sati. Model statički upravljivog trošila koristi diskretnu varijablu $s_{t,l}^{\text{stat}}$ koja može poprimiti vrijednost između 0 i 1 u 5 koraka, $s_{t,l}^{\text{stat}} \in [0, 0.2, 0.4, 0.6, 0.8, 1]$, gdje svaki korak predstavlja jednu jedinicu klimatizacijskog sustava snage 4.87 kW.

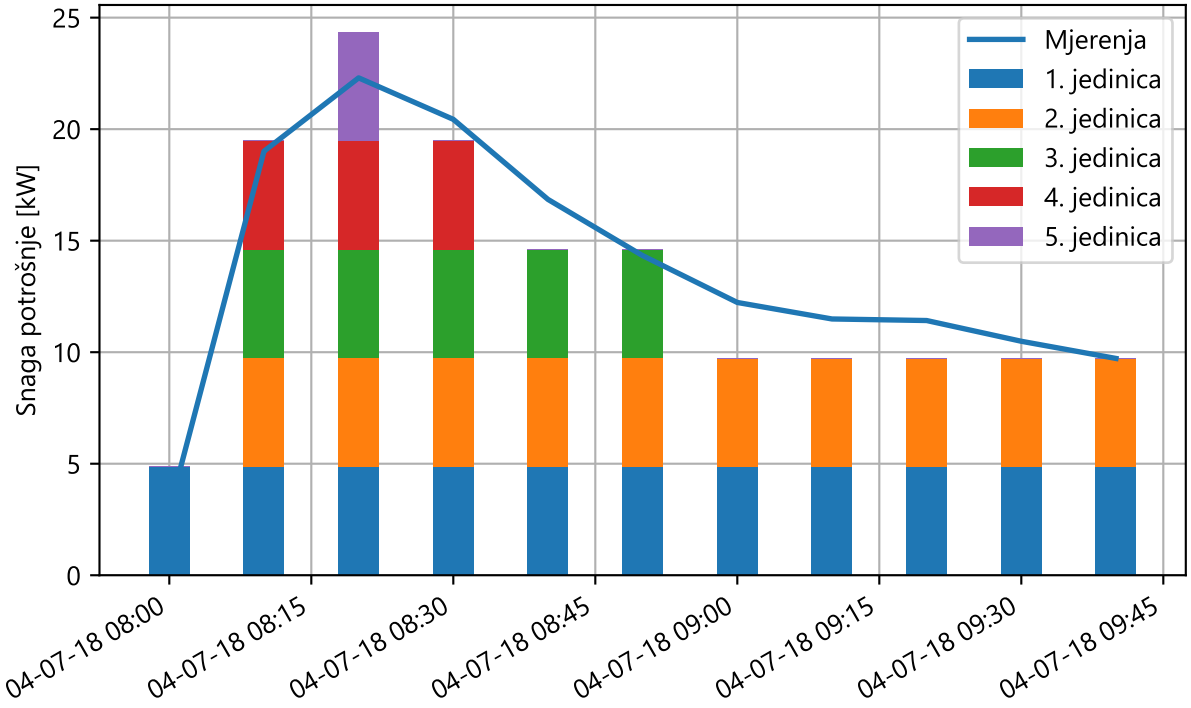

Slika 5.10: *Usporedba izmjerenog i planiranog profila snage potrošnje statički upravljivog trošila u obliku klimatizacijskog sustava s 5 jedinica za referentni slučaj*

Kako bi se spriječilo učestalo upravljanje potrošnjom i omogućilo upravljanje u nuždi (izoliran pogon mikromreže), definira se dodatni (virtualni) trošak upravljanja potrošnjom statički upravljivog trošila $c_{t,1}^{\text{stat}}$ koji odražava trošak narušavanja komfora korisnika mikromreže i definiran je izrazom 4-52. Trošak upravljanja ovisi o jediničnom trošku upravljanja c_1^{stat} i kontinuiranoj varijabli $s_{t,1}^{\text{stat}}$ (razina rasterećenja). Jedinični trošak upravljanja za modelirano statički upravljivo trošilo c_1^{stat} je definiran izrazom 5-4 i ovisi o koeficijentu $c_1^{\text{cur stat}}$ i trošku za opskrbu električnom energijom statički upravljivog trošila kada bi se sva energija preuzela od opskrbljivača (definirano izrazom 5-2), a trošilo radilo nazivnom snagom

$P_1^{\text{stat nom}}$ u iznosu od 24.35 kW. Iznos koeficijenta $c_1^{\text{cur stat}}$ je teško kvantificirati jer predstavlja novčanu vrijednost komfora korisnika mikromreže. U slučaju da je koeficijent $c_1^{\text{cur stat}}$ manji od 1, optimizacijski postupak bi gotovo uvijek koristio potpuno rasterećenje ovim tipom trošila jer je trošak upravljanja potrošnjom manji od troška za opskrbu potrošnje čime bi se generirala ušteda. Ako koeficijent $c_1^{\text{cur stat}}$ iznosi 1, to ujedno predstavlja isti trošak upravljanja kao trošak opskrbe potrošnje trošila. U slučaju kada je koeficijent $c_1^{\text{cur stat}}$ veći od 1, svako upravljanje potrošnjom ovim tipom trošilo predstavlja veći trošak u odnosu na trošak opskrbe potrošnje trošila. Iznosom koeficijenta $c_1^{\text{cur stat}}$ se također određuje kojim upravljivim elementom će se nadoknaditi manjak energije unutar mikromreže, mrežom (ako mikromreža radi u umreženom načinu rada), baterijskim sustavom pohrane energije, upravljivim generatorom ili rasterećenjem upravljivim trošilima. U referentnom slučaju vrijednost koeficijenta iznosi 10 kako bi se izbjeglo upravljanje potrošnjom u umreženom pogonu testne mikromreže, a omogućilo upravljanje potrošnjom u izoliranom (otočnom) načinu rada.

$$
\begin{aligned}
c_1^{\text{stat}} &= c_1^{\text{cur stat}} \cdot \left[c^{\text{grid buy}} \cdot P_1^{\text{stat nom}} \right] \quad \forall t \in T \\
c_1^{\text{stat}} &= c_1^{\text{cur stat}} \cdot \left[\left(c_j^{\text{energy buy}} + c_j^{\text{grid fee}} + c^{\text{RES fee}} \right) \cdot \left(1 + \frac{VAT}{100} \right) \cdot P_1^{\text{stat nom}} \right] \\
&\quad \forall t \in T, j \in \mathbb{Z}, j \in [1, 2]
\end{aligned}
\tag{5-4}
$$

Za potrebe simulacijskih slučajeva modelira se jedno vremenski odgodivo trošilo prema modelu opisanom u poglavlju 4.5.3. Vremenski odgodivo trošilo omogućuje odgodu potrošnje električne energije odnosno njeno premještanje u drugo vremensko razdoblje. Za potrebe simulacijskih slučajeva modelira se jedno vremenski odgodivo trošilo koje predstavlja električni automobil. Za potrebe modeliranja profila snage potrošnje vremenski odgodivog trošila koriste se mjerenja ciklusa punjenja električnog automobila na javnoj punionici s maksimalno dozvoljenom snagom punjenja vozila od 7.36 kW (32 A) izvršenog 3. prosinca 2020. godine u razdoblju od 16:40 sati do 21:40 sati prikazana na slici 5.11. Prikazane vrijednosti predstavljaju 10-minutne srednje vrijednosti snage potrošnje punionice. Ciklus punjenja električnog automobila traje ukupno 5 sati, a ukupna energija utrošena za punjenje je 29.8 kWh. Predstavljeni profil snage potrošnje na slici 5.11 koristi se u referentnom slučaju kao profil potrošnje vremenski odgodivog trošila. U referentnom slučaju, vremensko odgodivo trošilo priključeno je u testnu mikromrežu u 8:00 sati (t_1^{start}). Prema parametru t_1^{start} i poznatoj duljini trajanja ciklusa punjenja električnog vozila od 5 sati, vrijeme kraja planiranog profila potrošnje bez odgode t^{stop} je 13:00 sati. Ciklus trošila mora biti gotov do 17:00 sati (t_1^{end}). Maksimalni broj scenarija odgode $t_1^{\text{shft max}}$ se određuje prema izrazu 4-55 i iznosi 4 sata. Kako algoritam vremenski odgodivog trošila koristi isti vremenski korak kao

optimizacijski problem višeg sloja sustava upravljanja energijom (10 minuta), 4 sata iznosi 24 vremenska koraka.

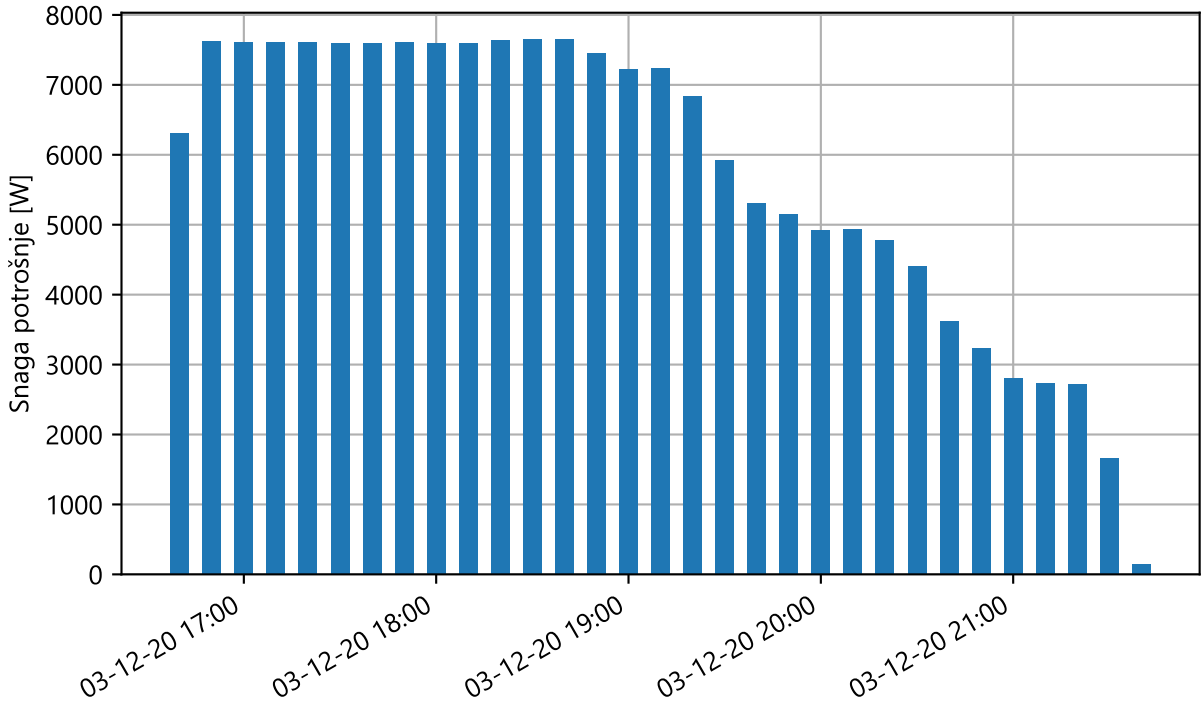

Slika 5.11: *Planirani profil snage potrošnje vremenski odgodivog trošila u obliku električnog automobila za referentni slučaj*

Radi bolje preglednosti, u tablici 5.13 se nalaze svi parametri korišteni prilikom modeliranja statički upravljivog i vremenski odgodivog trošila za referentni slučaj.

Tablica 5.13: *Iznosi parametara modela statički upravljivog i vremenski odgodivog trošila za referentni slučaj*

Parametar	**Iznos**
$P_1^{\text{stat nom}}$ [kW]	24.35
$c_1^{\text{cur stat}}$	10
t_1^{start} [h]	8:00
t_1^{stop} [h]	13:00
t_1^{end} [h]	17:00
$t_1^{\text{shft max}}$ [h]	4:00

5.3. Treniranje i testiranje umjetnih neuronskih mreža s dugom kratkoročnom memorijom

Za srednjoročno i kratkoročno prognoziranje ulaznih parametara u optimizacijske probleme slojeva sustava upravljanja energijom koriste se umjetne neuronske mreže s dugom kratkoročnom memorijom, opisane u poglavlju 4.8.1, čije karakteristike ovise o veličini koju predviđaju i sloju (optimizacijskom problemu) sustava upravljanja energijom za koji se koriste. Pregled karakteristika umjetnih neuronskih mreža korištenih za predviđanje ulaznih parametara prikazan je u tablici 5.14. Umjetne neuronske mreže s dugom kratkoročnom memorijom korištene u ovoj disertaciji realizirane su u *Keras* paketu za viši programski jezik *Python*. *Keras* predstavlja aplikacijsko programsko sučelje za *TensorFlow* platformu za duboko učenje [132]. *Keras* omogućuje razvoj, treniranje i testiranje različitih vrsta umjetnih neuronskih mreža.

Tablica 5.14: *Karakteristike umjetnih neuronskih mreža s dugom kratkoročnom memorijom korištenih za predviđanje ulaznih parametara u optimizacijske probleme slojeva sustava upravljanja energijom*

Sloj	**Horizont predviđanja**	**Vremenski korak**	**Veličina**
Viši sloj	24 sata	10 minuta	Snaga potrošnje (neupravljive) električne energije mikromreže
Niži sloj	10 minuta	1 minuta	Snaga potrošnje (neupravljive) električne energije mikromreže
	10 minuta	1 minuta	Snaga sunčevog zračenja
	10 minuta	1 minuta	Temperatura okoliša

Kako su umjetne neuronske mreže podatkovno orijentirane i adaptivne metode za predviđanje, proces učenja se zasniva na velikom broju podataka koje u ovom slučaju predstavljaju mjerenja električnih i meteoroloških veličina. Kao što je već opisano u poglavlju 4.8.1, umjetne neuronske mreže s dugom kratkoročnom memorijom trenirat će se pomoću nadziranog učenja.

Podaci za treniranje umjetnih neuronskih mreža preuzeti su iz *online* baze podataka Laboratorija za obnovljive izvore energije FERIT-a Osijek [131]. Podaci predstavljaju mjerenja električnih veličina i meteoroloških parametara na lokaciji zgrade FERIT Osijek na adresi Kneza Trpimira 2B, 31000 Osijek u razdoblju od 6. ožujka 2017. do 8. svibnja 2019. godine. Osim mjerenja potrošnje električne energije zgrade FERIT-a (prikazana na slici 5.9), za treniranje neuronske mreže koristit će se i mjerenja meteoroloških parametara kao što su snaga sunčevog zračenja, temperatura okoliša, vlažnost zraka, brzina vjetra i tlak zraka čiji su profili u promatranom razdoblju prikazani na slici 5.12. Podaci prikazani na slikama

5.9 i 5.12 su u *online* bazi podataka dostupni u različitim vremenskim razinama, a za potrebe treniranja umjetnih neuronskih mreža će se koristiti 10-minutne i 1-minutne srednje vrijednosti, prema karakteristikama prikazanim u tablici 5.14.

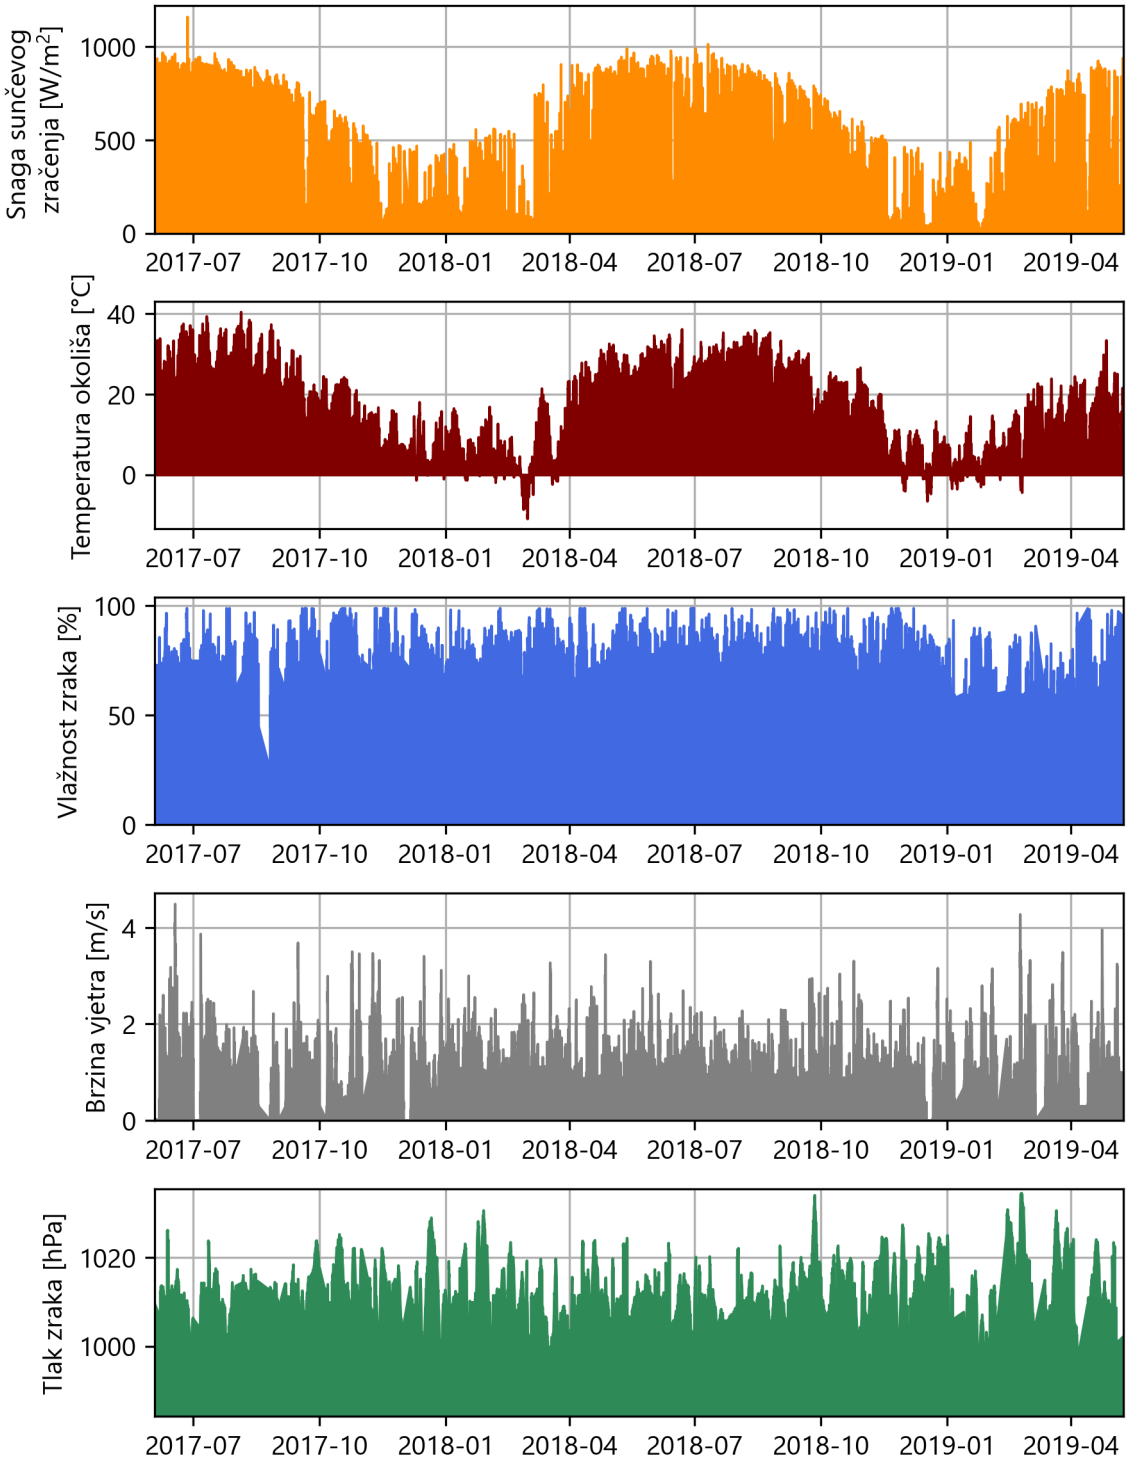

Slika 5.12: *Ulazni meteorološki parametri u umjetnu neuronsku mrežu*

Osim profila prikazanih na slikama 5.9 i 5.12, kao ulazni podaci za predviđanje profila snage potrošnje električne energije mikromreže koriste se sljedeći neelektrički i nemeteorološki

parametri:

- Trenutno vrijeme u danu;
- Redni broj dana u godini;
- Redni broj tjedna u godini;
- Redni broj dana u tjednu;
- Indikator vikend dana;
- Indikator blagdana i neradnog dana.

Trenutno vrijeme u danu je izraženo numerički decimalnim brojem s vrijednošću između 0 i 24, redni broj dana u godini poprima numeričku vrijednost između 1 i 365, redni broj tjedna u godini poprima numeričku vrijednost između 1 i 52, redni broj dana u tjednu poprima numeričku vrijednost između 1 i 7 gdje 1 označuje ponedjeljak, a 7 nedjelju. Indikator vikend dana je binarna varijabla koja poprima numeričku vrijednost 1 kada je promatrani dan subota ili nedjelja, a 0 za sve ostale dane u tjednu. Indikator blagdana i neradnog dana je binarna varijabla koja poprima numeričku vrijednost 1 kada je promatrani dan blagdan ili neradni dan u Republici Hrvatskoj, a 0 kada nije.

Svi ulazni podaci u umjetne neuronske mreže normalizirani su na vrijednost između 0 i 1 prema izrazu 4-81 kako bi se uklonio utjecaj dimenzijskih razlika između veličina. Shematski prikaz topologije korištene umjetne neuronske mreže kao i vektori ulaznih i izlaznih veličina umjetne neuronske mreže prikazan je na slici 5.13. Izlaz iz umjetnih neuronskih mreža predstavlja vektor (profil) s vrijednostima predviđane veličine za razdoblje od trenutka t do trenutka $t+n$ u budućnosti, gdje parametri t i n ovise o sloju sustava upravljanja energijom za koji se promatrana umjetna neuronska mreža koristi, a definirani su u tablici 5.14. Izlazna veličina se predviđa na osnovu vektora ulaznih veličina s povijesnim vrijednostima pojedine ulazne veličine za razdoblje od trenutka $t-m$ do trenutka $t-1$ gdje parametri t i m također ovise o umjetnoj neuronskoj mreži.

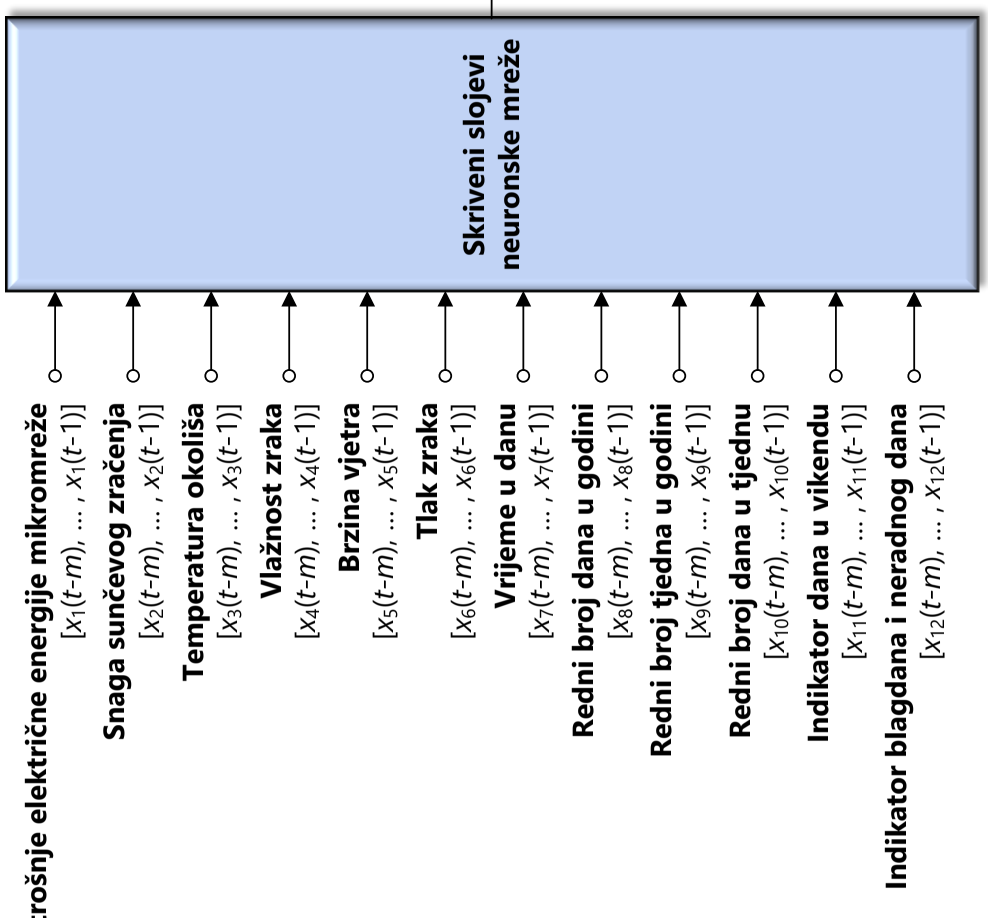

Slika 5.13: *Shematski prikaz umjetne neuronske mreže s dugom kratkoročnom memorijom korištene za predviđanje ulaznih parametara u optimizacijske probleme slojeva sustava upravljanja energijom za referentni slučaj*

5.3.1. Rezultati treniranja i testiranja umjetne neuronske mreže za predviđanje snage potrošnje električne energije mikromreže u višem sloju

Umjetna neuronska mreža korištena u ovom sloju sustava upravljanja energijom koristi topologiju prikazanu na slici 5.13. Duljina vektora izlazne veličine iznosi 24 sata (horizont predviđanja PH_i) što odgovara 144 vremenska koraka optimizacijskog problema višeg sloja sustava upravljanja energijom (parametar n). Izlazna veličina predviđa se pomoću vektora s povijesnim vrijednostima ulaznih veličina za posljednjih 24 sata što odgovara 144 vremenska koraka (parametar m).

Arhitektura i postavke umjetne neuronske mreže određene su empirijskim postupkom izvršavanjem velikog broja iteracija treniranja umjetne neuronske mreže. Za prijenosnu funkciju skrivenih slojeva korištena je funkcija tangens hiberpbolni (th). Umjetna neuronska mreža je trenirana pomoću *Nadam* programa za numeričko rješavanje (*solver*) optimizacijskog problema [133]. Spomenuti program za numeričko rješavanje optimizacijskog problema postigao je najmanju pogrešku predviđanja prilikom treniranja umjetne neuronske mreže. *Nadam* je inačica programa za numeričko rješavanje *Adam* s ugrađenim Nesterovljevim momentom (engl. *Nesterov momentum*) [134]. *Adam* je program za numeričko rješavanje temeljen na stohastičkom gradijentnom spustu koji kombinira prednosti *Adagrad* (engl. *Adaptive gradient algorithm*) i *RMSprop* (engl. *Root-mean-square propagation*) programa za numeričko rješavanje.

Poznati skup podataka (mjerenja) dijeli se na skup za treniranje i skup za provjeru vladanja umjetne neuronske mreže. Skup za provjeru vladanja umjetne neuronske mreže podijeljen je na skup za validaciju odnosno uspoređivanje izlaznih veličina sa željenim (engl. *Validation set*) i testni skup (engl. *Testing set*). Skup za provjeru vladanja umjetne neuronske mreže ne koristi se prilikom treniranja umjetne neuronske mreže kako bi se ocijenila točnost predviđanja. Umjetna neuronska mreža testirana je na skupu podataka duljine jednog tjedna (1008 vremenskih koraka) što rezultira s 1008 iteracija predviđanja. Testni skup ispituje vladanje umjetne neuronske mreže za sve dane u tjednu uzimajući u obzir i radne dane i vikend dane. Ostatak poznatog skupa podataka dijeli se na skup za treniranje (učenje) i skup za uspoređivanje izlaznih veličina sa željenim (validaciju) u omjeru 75 : 25 % što odgovara omjeru uzoraka (10-minutnih srednjih vrijednosti) 75924 : 25309.

Empirijskim postupkom određena je arhitektura umjetne neuronske mreže s dva skrivena sloja u kojoj 1. skriveni sloj ima 50 LSTM ćelija, a 2. skriveni sloj 30 LSTM ćelija. Treniranje mreže je izvršeno za 50 epoha (engl. *Epoch*) dok su ulazni podaci unošeni u serijama (engl. *Batch*) od 15 slijednih vrijednosti. Treniranje umjetne neuronske mreže izvršeno je na računalu s Intel Core i5-9400F 2.9 GHz procesorom i 8 GB DD4 RAM memorijom u tra-

janju od 4:58 sati. Prikaz srednje apsolutne pogreške kroz epohe tijekom treniranja umjetne neuronske mreže na skupu za treniranje i skupu za validaciju vidljiv je na slici 5.14. Treba zamijetiti da je na slici 5.14 prikazana srednja apsolutna pogreška izračunana za normalizirane vrijednosti (između 0 i 1) svih ulaznih i izlaznih veličina u umjetnu neuronsku mrežu. Prilikom testiranja umjetne neuronske mreže, svi podaci se vraćaju u izvornu dimenziju kako bi se lakše vizualno i numerički odredila točnost predviđanja.

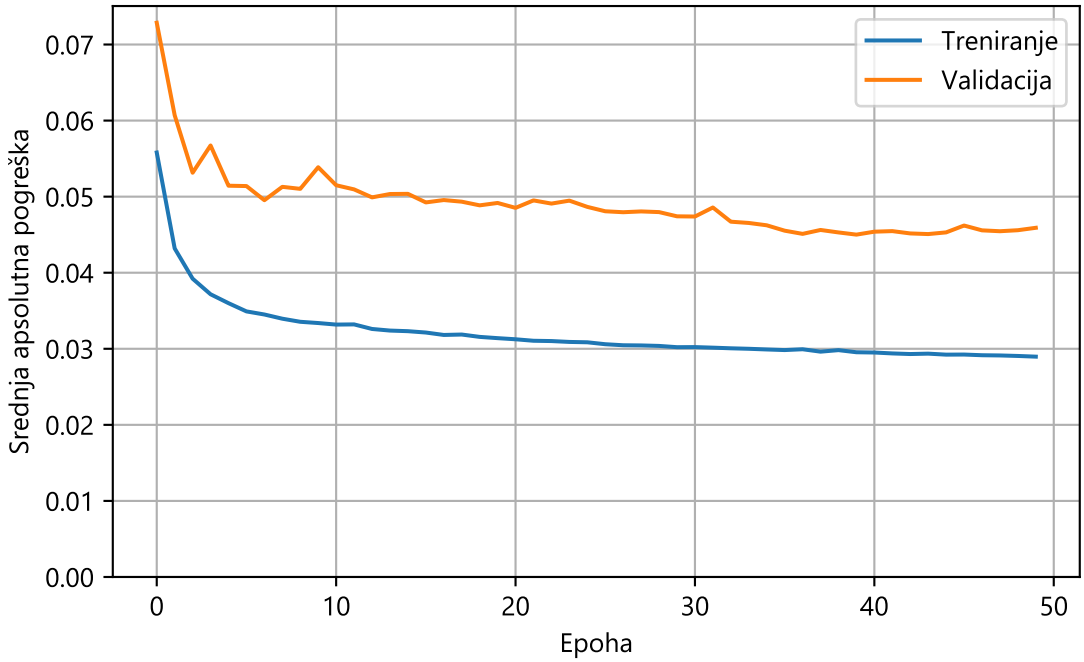

Slika 5.14: *Srednja apsolutna pogreška kroz epohe tijekom treniranja umjetne neuronske mreže na skupu za treniranje i skupu za validaciju*

Kako se prognoze ulaznih parametara u optimizacijske probleme oba sloja sustava upravljanja energijom osvježavaju u svakoj iteraciji (slika 3.2), treba imati na umu da se rezultati predviđanja mogu prikazati na više načina. Statistički indeksi pogreške za ocjenu performansi (točnosti) predviđanja mogu se računati za svaki pojedini horizont predviđanja (144 koraka u budućnosti) u svakoj iteraciji ili za svaki pojedini vremenski korak u budućnosti svih iteracija. Na slici 5.15 prikazan je rezultat predviđanja profila snage potrošnje mikromreže za cijeli testni skup (1 tjedan) i to samo za prvi korak u budućnosti (t) svake iteracije, što ujedno i predstavlja horizont upravljanja za koji se generirane varijable odluke u optimizacijskom problemu višeg sloja šalju u optimizacijski problem nižeg sloja. Srednja apsolutna pogreška predviđanja samo prvog koraka u budućnosti (za cijeli testni skup) iznosi $MAE = 3.8$ kW, korijen srednje kvadratne pogreške $RMSE = 4.1$ kW, a koeficijent korelacije $R = 98.57$ %. Prikaz točnosti predviđanja profila snage potrošnje vidljiv je i na raspršenom grafu na slici 5.16 gdje su na x-osi prikazane stvarne vrijednosti, a na y-osi predviđene vrijednosti snage potrošnje električne energije mikromreže za promatrani horizont predviđanja

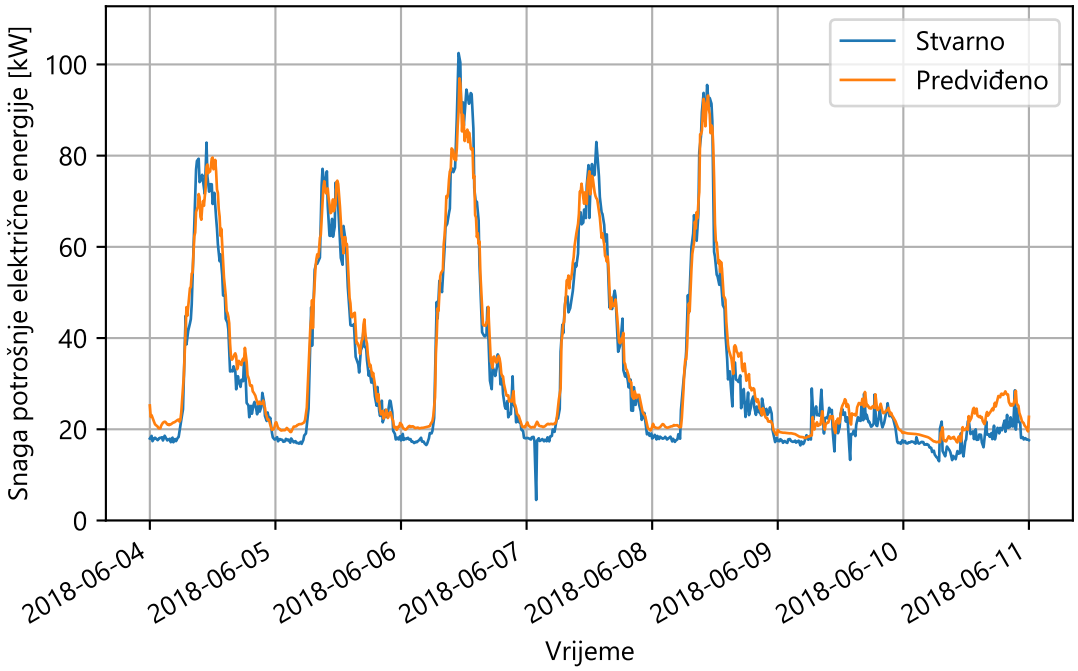

Slika 5.15: *Rezultat predviđanja profila snage potrošnje mikromreže za prvi korak u budućnosti za cijeli testni skup*

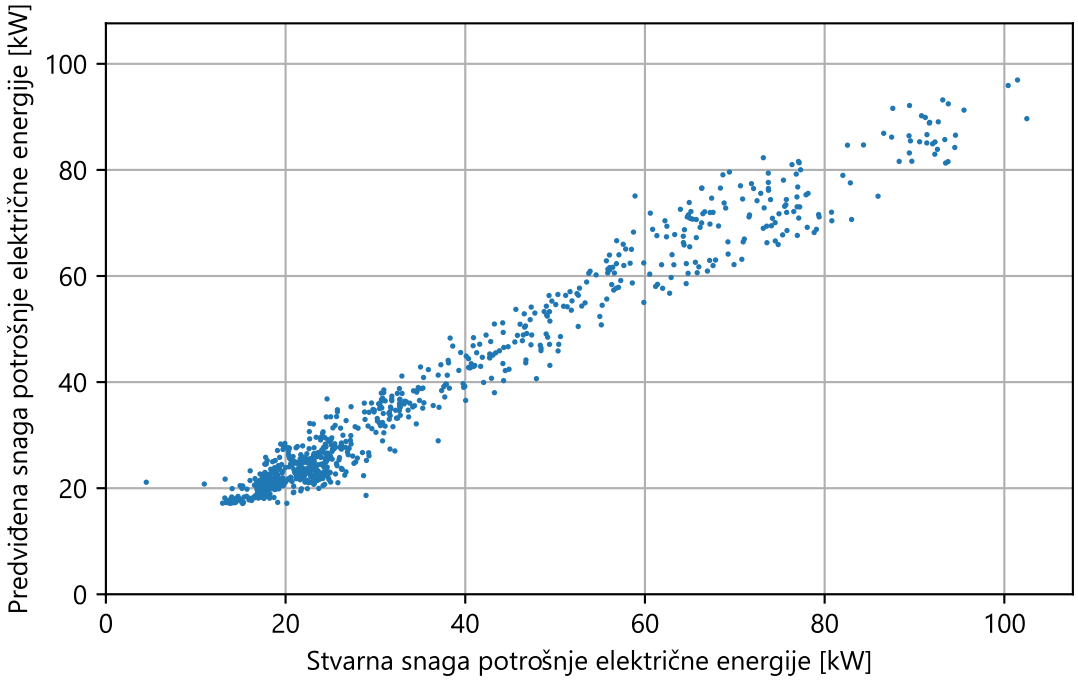

Slika 5.16: *Odnos predviđene i stvarne potrošnje mikromreže za prvi korak u budućnosti za cijeli testni skup*

Srednja apsolutna pogreška MAE, korijen srednje kvadratne pogreške $RMSE$ i koeficijent korelacije R za svaki pojedini vremenski korak u budućnosti svih iteracija prikazani su

na slici 5.17. Na slici 5.17 uočava se kako srednja apsolutna pogreška MAE i korijen srednje kvadratne pogreške $RMSE$ rastu s vremenskim korakom koji se predviđa u budućnosti dok koeficijent korelacije R pada. Ovo je očekivano jer se pogreška predviđanja povećava s vremenskom udaljenosti od trenutka predviđanja (koraka koji se predviđa u budućnosti).

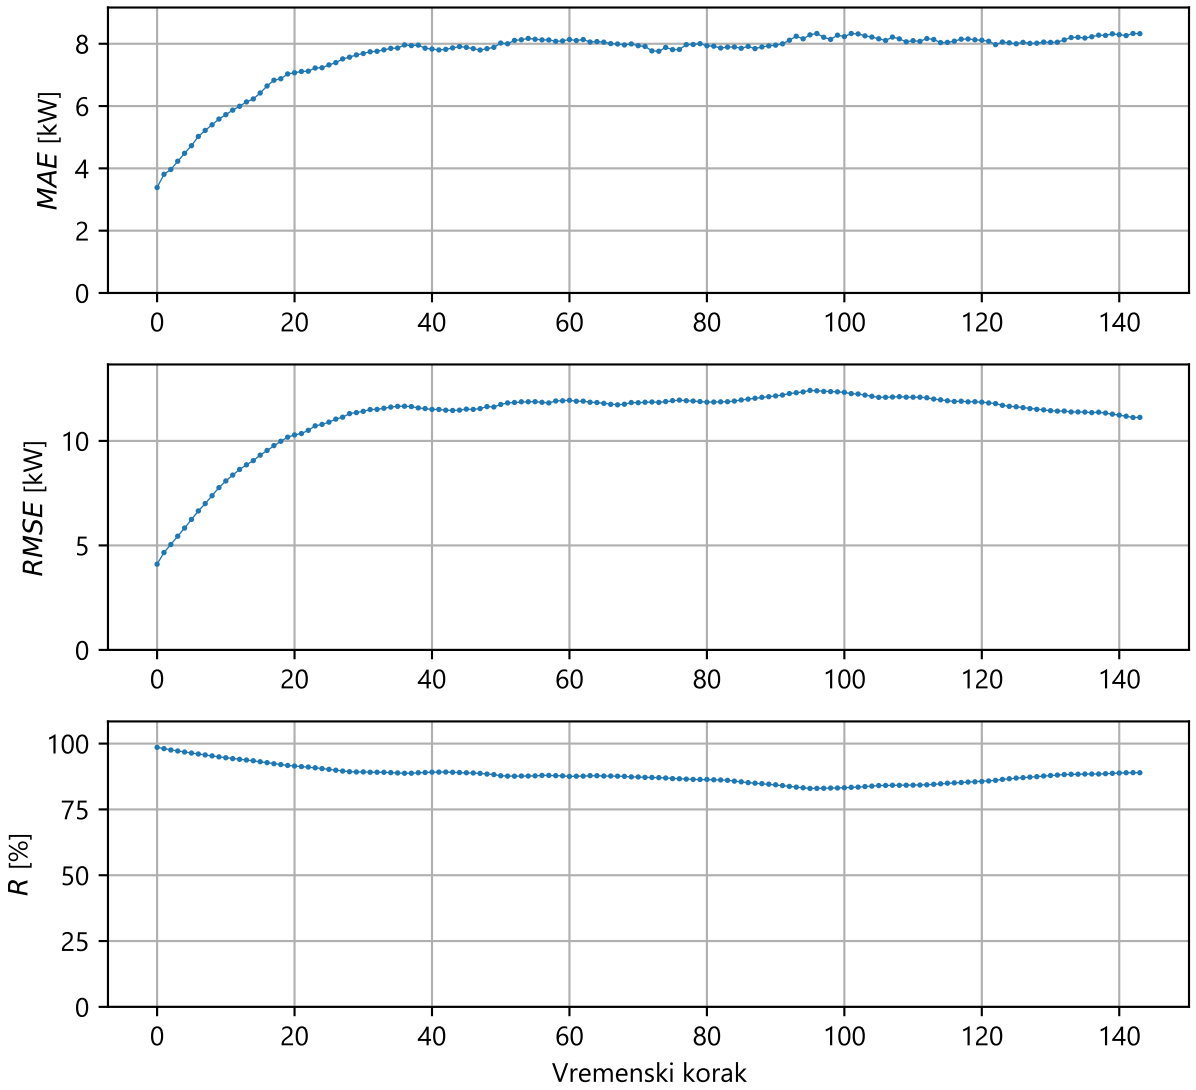

Slika 5.17: *Srednja apsolutna pogreška MAE, korijen srednje kvadratne pogreške $RMSE$ i koeficijent korelacije R za sve pojedine vremenske korake predviđanja u budućnosti za cijeli horizont predviđanja*

Za detaljniju analizu performansi predviđanja (točnost) u nastavku su prikazani rezultati predviđanja za pojedine dane (horizont predviđanja) testnog skupa. Do sada su prikazani rezultati samo za prvi korak u budućnosti svih iteracija, stoga se ovdje prikazuju rezultati pojedine iteracije predviđanja za cijeli horizont predviđanja u budućnosti (1 dan). Rezultati predviđanja profila snage potrošnje mikromreže za ljetni radni dan su prikazani na slici 5.18. Srednja apsolutna pogreška za promatrani horizont predviđanja prikazan na slici 5.18 iznosi $MAE = 5.68$ kW, korijen srednje kvadratne pogreške $RMSE = 6.65$ kW, a koeficijent

korelacije $R = 96.39$ %. Prikaz točnosti predviđanja profila snage potrošnje vidljiv je i na raspršenom grafu na slici 5.19 gdje su na x-osi prikazane stvarne vrijednosti, a na y-osi predviđene vrijednosti snage potrošnje električne energije mikromreže za promatrani horizont predviđanja.

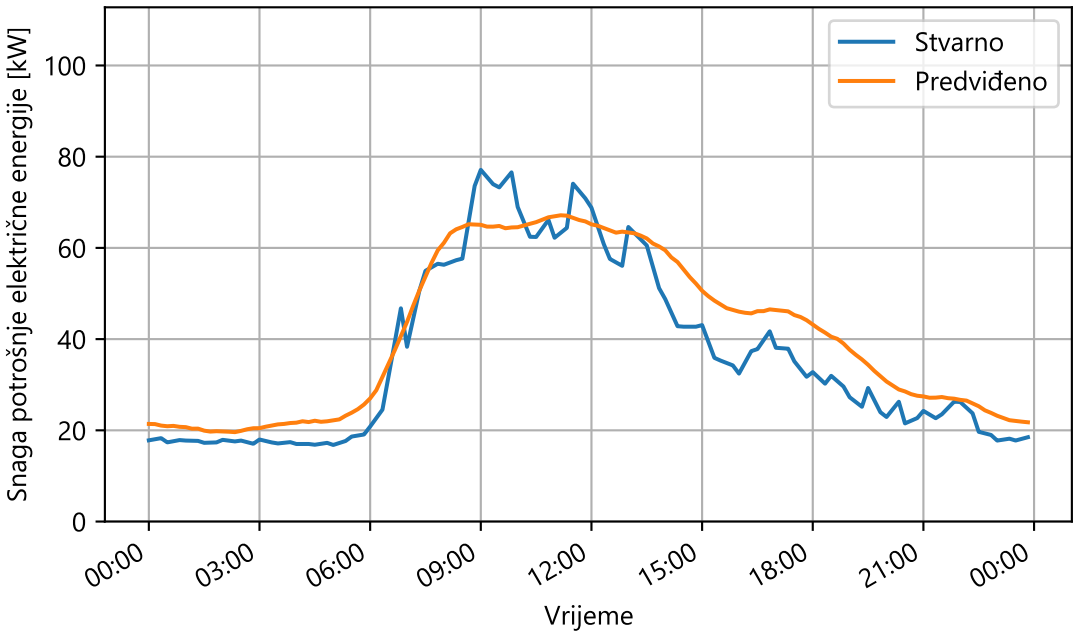

Slika 5.18: *Rezultati predviđanja profila snage potrošnje mikromreže za ljetni radni dan*

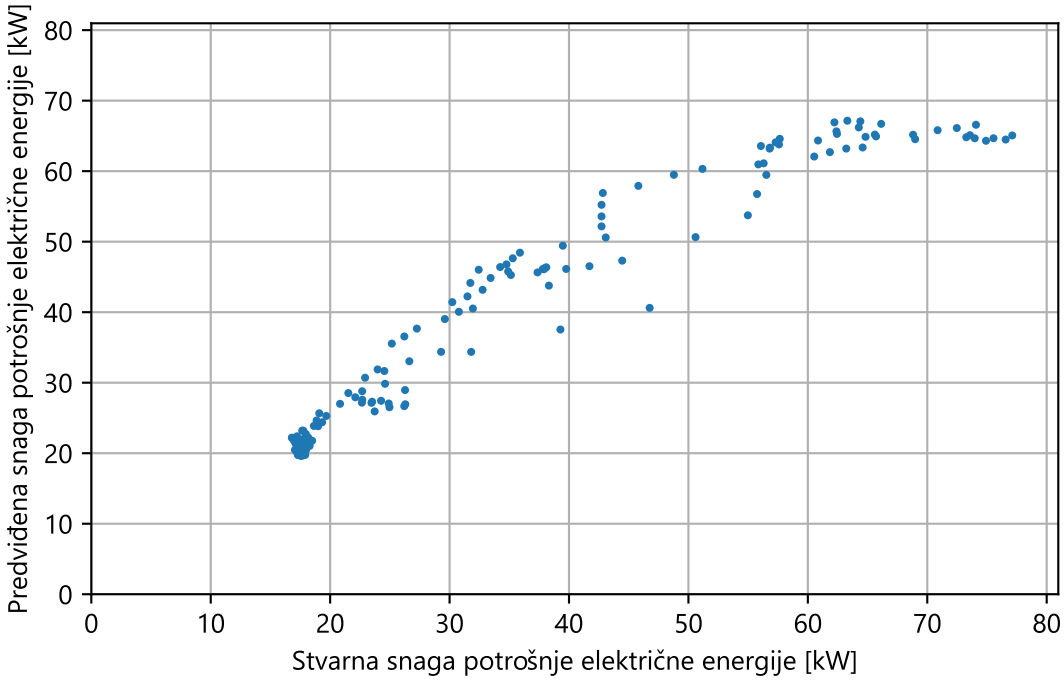

Slika 5.19: *Odnos predviđene i stvarne snage potrošnje električne energije mikromreže za ljetni radni dan*

Prognoze ulaznih parametara u optimizacijske probleme oba sloja sustava upravljanja energijom osvježavaju se u svakoj iteraciji što rezultira prilagodbom predviđanja izlazne veličine jer su u svakoj novoj iteraciji dostupna novija mjerenja stvarnih veličina (ulazni podaci). Ovo je vidljivo na slici 5.20 gdje su radi bolje preglednosti prikazani predviđeni profili snage potrošnje za svakih 2 sata (12 vremenskih koraka optimizacijskog problema) iako se predviđanje vrši za svaki vremenski korak. U svakoj novoj iteraciji poznati su novi ulazni podaci umjetne neuronske mreže koji za rezultat imaju prilagodbu predviđanja buduće snage potrošnje mikromreže.

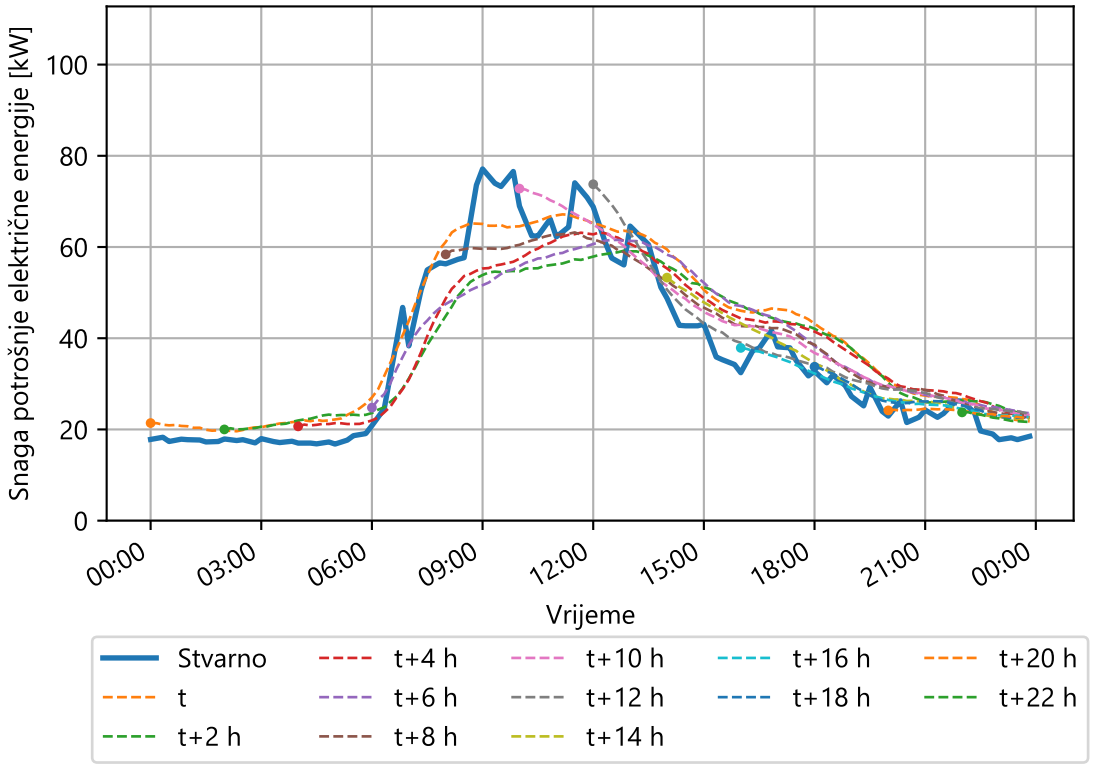

Slika 5.20: *Rezultati predviđanja profila snage potrošnje mikromreže za ljetni radni dan u više iteracija*

Prikaz rezultata predviđanja profila snage potrošnje mikromreže za ljetni vikend dan u više iteracija prikazan je na slici 5.21. Srednja apsolutna pogreška za horizont predviđanja t prikazan na slici 5.21 iznosi $MAE = 5.82$ kW, korijen srednje kvadratne pogreške $RMSE = 6.14$ kW, a koeficijent korelacije $R = 71.97$ %.

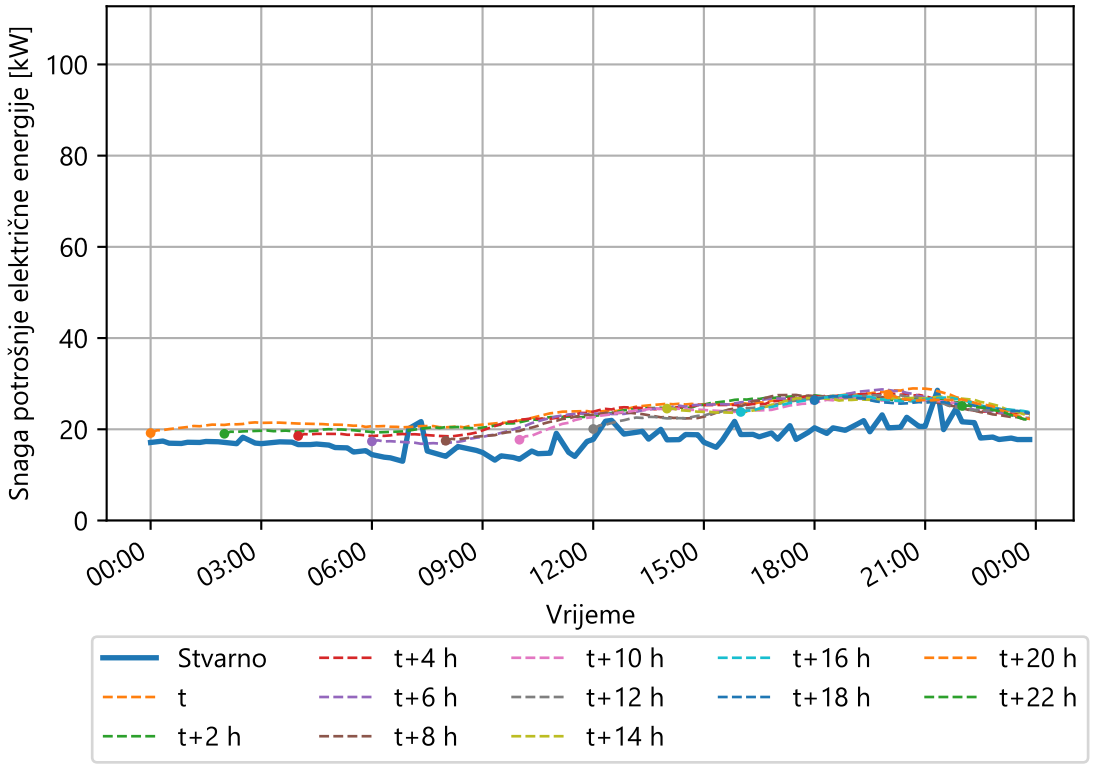

Slika 5.21: *Rezultati predviđanja profila snage potrošnje mikromreže za ljetni vikend dan u više iteracija*

5.3.2. Rezultati treniranja i testiranja umjetnih neuronskih mreža za predviđanje ulaznih parametara u optimizacijski problem nižeg sloja

Ulazni parametri u optimizacijski problem nižeg sloja sustava upravljanja energijom predviđaju se pomoću tri umjetne neuronske mreže karakteristika sličnih umjetnoj neuronskoj mreži korištenoj za predviđanje profila snage potrošnje mikromreže za viši sloj sustava upravljanja energijom predstavljenoj u poglavlju 5.3.1. Kroz daljnji tekst korištene su sljedeće oznake za ove tri umjetne neuronske mreže: prva umjetna neuronska mreža koristi oznaku ANN1 i predviđa profil snage potrošnje električne energije mikromreže, druga umjetna neuronska mreža koristi oznaku ANN2 i predviđa profil snage sunčevog zračenja dok treća umjetna neuronska mreža koristi oznaku ANN3 i predviđa profil temperature okoliša. Duljina vektora izlazne veličine iznosi 10 minuta što odgovara 10 vremenskih koraka optimizacijskog problema nižeg sloja sustava upravljanja energijom (parametar n na slici 5.13). Izlazna veličina predviđa se pomoću vektora s povijesnim vrijednostima ulaznih veličina za posljednjih 10 minuta što odgovara 10 vremenskih koraka (parametar m prema slici 5.13). Također treba naglasiti da se izlazna veličina u umjetnim neuronskim mrežama ANN2 (snaga sunčevog zračenja) i ANN3 (temperatura okoliša) predviđa pomoću 11 ulaznih vektora (umjesto 12 prema slici 5.13) jer se ne koristi ulazni vektor s podacima o potrošnji

električne energije mikromreže o kojoj se smatra da izlazna veličina ne ovisi. Arhitektura i postavke umjetnih neuronskih mreža korištenih u nižem sloju sustava upravljanja energijom odgovara arhitekturi i postavkama umjetne neuronske mreže korištene u višem sloju: prijenosna funkcija skrivenih slojeva je tangens hiperbolni (th), korišteni program za numeričko rješavanje je *Nadam*, umjetna neuronska mreža koristi dva skrivena sloja gdje prvi ima 50 LSTM ćelija, a drugi 30 LSTM ćelija. Poznati skup podataka pomoću kojega se umjetne neuronske mreže treniraju i provjerava njihovo vladanje ima frekvenciju uzorkovanja od 1 minute za razliku od prošlog slučaja gdje je frekvencija uzorkovanja bila 10 minuta, a što ovisi o karakteristikama umjetnih neuronskih mreža prikazanim u tablici 5.14. Umjetne neuronske mreže testirane su na skupu podataka duljine jednog tjedna (10080 vremenskih koraka). Kako se optimizacijski postupak u nižem sloju sustava upravljanja energijom vrši korak-po-korak za cijeli horizont planiranja u jednoj iteraciji, zahtijeva se dostupnost ulaznih parametara u optimizacijski problem (prognoze) za cijeli horizont planiranja prije početka optimizacijskog procesa. Ovo rezultira sa sveukupno 1008 iteracija predviđanja (10080/10) ulaznih podataka u optimizacijski problem nižeg sloja sustava upravljanja. Izuzevši testni skup od skupa poznatih podataka dobiva se skup za treniranje i skup za uspoređivanje (validaciju) koji se također dijeli u omjeru 75 : 25 % što odgovara omjeru uzoraka (1-minutnih srednjih vrijednosti) 753840 : 251280. Izvršeno je treniranje mreže za 50 epoha dok su ulazni podaci uneseni u serijama (engl. *Batch*) od 15 slijednih vrijednosti. Treniranje umjetne neuronske mreže izvršeno je na računalu s Intel Core i5-9400F 2.9 GHz procesorom i 8 GB DD4 RAM memorijom u prosječnom trajanju od 4 sata.

Prikaz srednje apsolutne pogreške kroz epohe tijekom treniranja sve tri umjetne neuronske mreže (ANN1, ANN2 i ANN3) na skupu za treniranje i skupu za validaciju vidljiv je na slici 5.22. Kao i u prošlom slučaju treba zamijetiti da je na slici 5.22 prikazana srednja apsolutna pogreška izračunana za normalizirane vrijednosti (između 0 i 1) svih ulaznih i izlaznih veličina u umjetnu neuronsku mrežu. Prilikom testiranja umjetnih neuronskih mreža svi se podaci vraćaju u izvornu dimenziju kako bi se lakše vizualno i numerički odredila točnost predviđanja. Za razliku od višeg sloja sustava upravljanja energijom, za kojeg se prognoze ulaznih parametara vrše u svakoj iteraciji odnosno za svaki vremenski korak, umjetne neuronske mreže korištene u nižem sloju sustava upravljanja energijom predviđaju za cjelokupni horizont upravljanja višeg sloja (što je jednako horizontu planiranja nižeg sloja) odjednom. Prema tome, statistički indeksi pogreške za ocjenu performansi (točnosti) predviđanja umjetnih neuronskih mreža mogu se računati za svaki horizont predviđanja (horizont upravljanja višeg sloja odnosno horizont planiranja nižeg sloja) u budućnosti (10 vremenskih koraka) ili za svaki pojedini vremenski korak u budućnosti, svih iteracija. Radi bolje preglednosti, samo su rezultati performansi (točnosti) predviđanja umjetnih neuronske

mreže ANN1 prikazani u ovom poglavlju dok su rezultati predviđanja umjetnih neuronskih mreža ANN2 i ANN3 prikazani u prilozima.

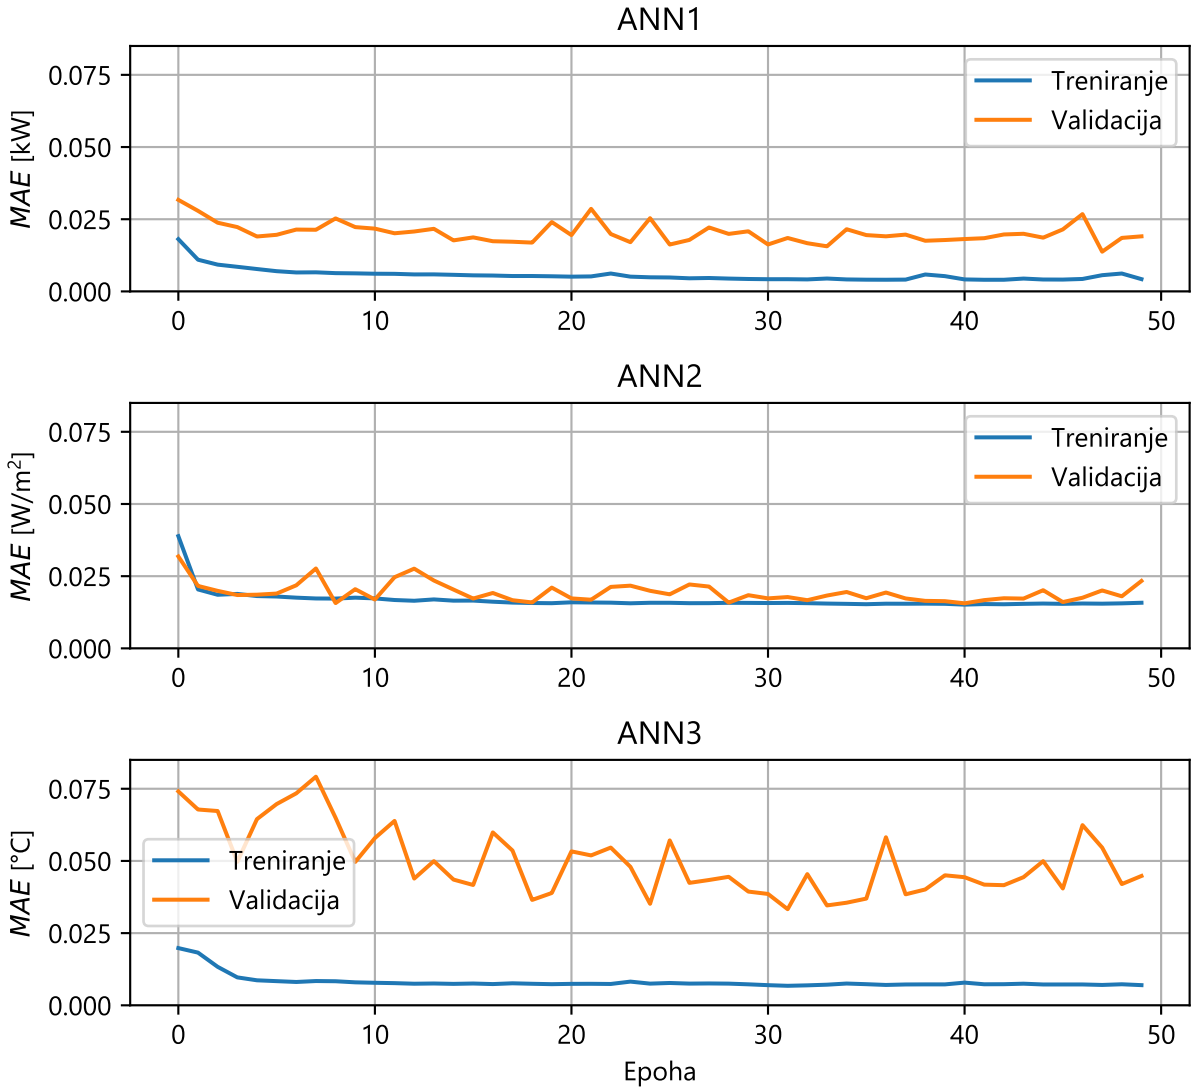

Slika 5.22: *Srednja apsolutna pogreška kroz epohe tijekom treniranja umjetnih neuronskih mreža ANN1, ANN2 i ANN3 na skupu za treniranje i skupu za validaciju*

Na slici 5.23 prikazan je rezultat predviđanja profila snage potrošnje mikromreže za cijeli testni skup (1 tjedan) pomoću umjetne neuronske mreže ANN1. Srednja apsolutna pogreška predviđanja za cijeli testni skup iznosi $MAE = 2.6$ kW, korijen srednje kvadratne pogreške $RMSE = 3.35$ kW, a koeficijent korelacije $R = 99.56$ %. Rezultat predviđanja profila snage sunčevog zračenja (ANN2) i profila temperature okoliša (ANN3) prikazan je za jedan dan radi bolje preglednosti. Slika P.1 u prilogu prikazuje rezultat predviđanja profila snage sunčevog zračenja za jedan dan iz testnog skupa pomoću umjetne neuronske mreže ANN2. Srednja apsolutna pogreška za predviđanja za cijeli testni skup iznosi $MAE = 74.03$ W/m^2, korijen srednje kvadratne pogreške $RMSE = 131.66$ W/m^2, a koeficijent korelacije $R =$

93.66 %. Rezultat predviđanja profila temperature okoliša za jedan dan iz testnog skupa pomoću umjetne neuronske mreže ANN3 vidljiv je na slici P.2 u prilozima. Srednja apsolutna pogreška predviđanja za cijeli testni skup iznosi $MAE = 1.51$ °C, korijen srednje kvadratne pogreške $RMSE = 1.9$ °C, a koeficijent korelacije $R = 97.4$ %.

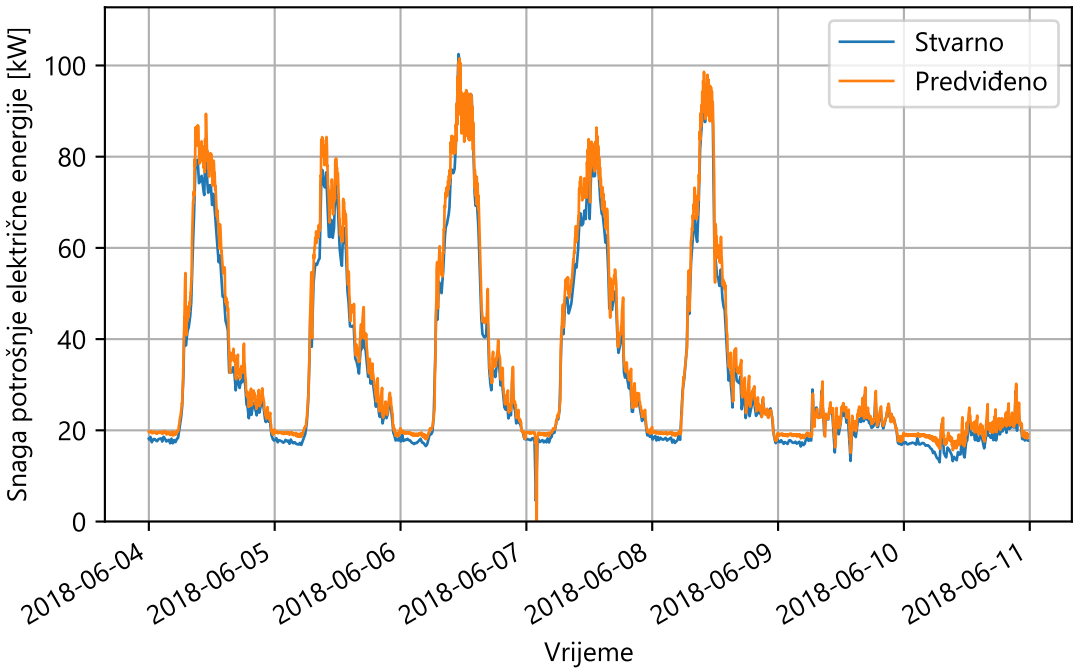

Slika 5.23: *Rezultat predviđanja profila snage potrošnje mikromreže za cijeli testni skup pomoću umjetne neuronske mreže ANN1*

Prikaz točnosti predviđanja profila snage potrošnje električne energije mikromreže pomoću umjetne neuronske mreže ANN1 vidljiv je i na raspršenom grafu na slici 5.24 gdje su na x-osi prikazane stvarne vrijednosti, a na y-osi predviđene vrijednosti snage potrošnje električne energije mikromreže za cijeli testni skup. Grafički prikaz istog odnosa veličina za ANN2 i ANN3 vidljiv je na slici P.3 i slici P.4, slijedno.

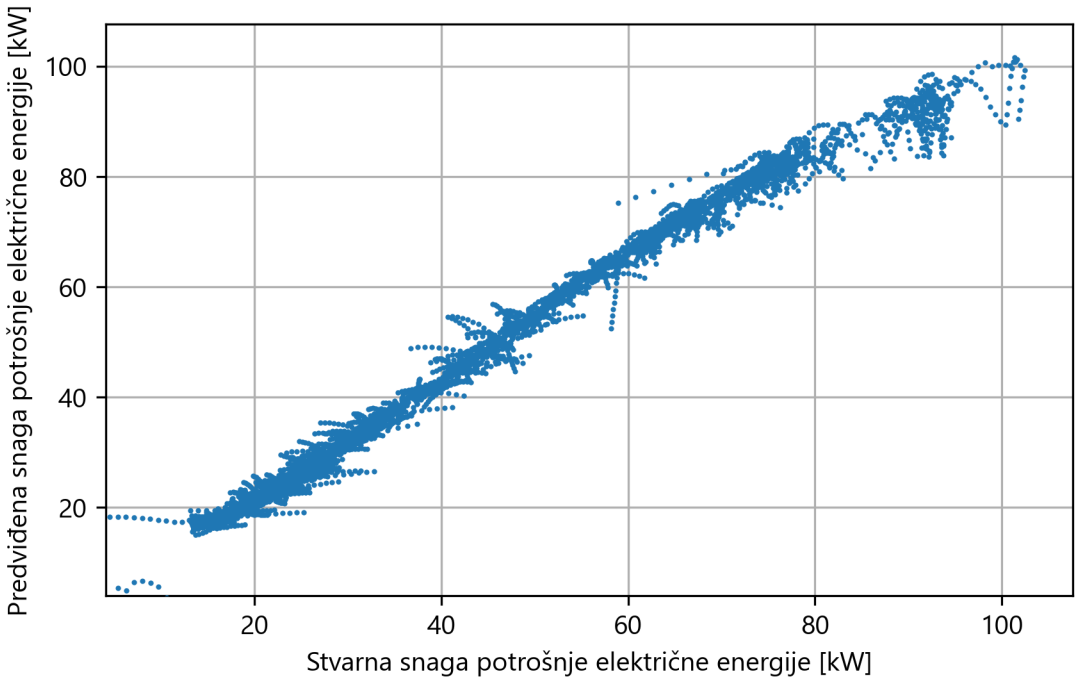

Slika 5.24: *Odnos predviđene i stvarne snage potrošnje električne mikromreže za cijeli testni skup pomoću umjetne neuronske mreže ANN1*

Srednja apsolutna pogreška MAE, korijen srednje kvadratne pogreške $RMSE$ i koeficijent korelacije R za svaki pojedini vremenski korak u budućnosti svih iteracija za umjetnu neuronsku mrežu ANN1 prikazani su na slici 5.25. Grafički prikaz istih veličina za umjetne neuronske mreže ANN2 i ANN3 vidljiv je na slici P.5 i slici P.6 u prilogu, slijedno. Na slici 5.25 primjećuje se kako srednja apsolutna pogreška MAE i korijen srednje kvadratne pogreške $RMSE$ rastu s vremenskim korakom koji se predviđa u budućnosti dok koeficijent korelacije R pada. Ovo je očekivano jer se pogreška predviđanja povećava s vremenskom udaljenosti od trenutka predviđanja (koraka koji se previđa u budućnosti).

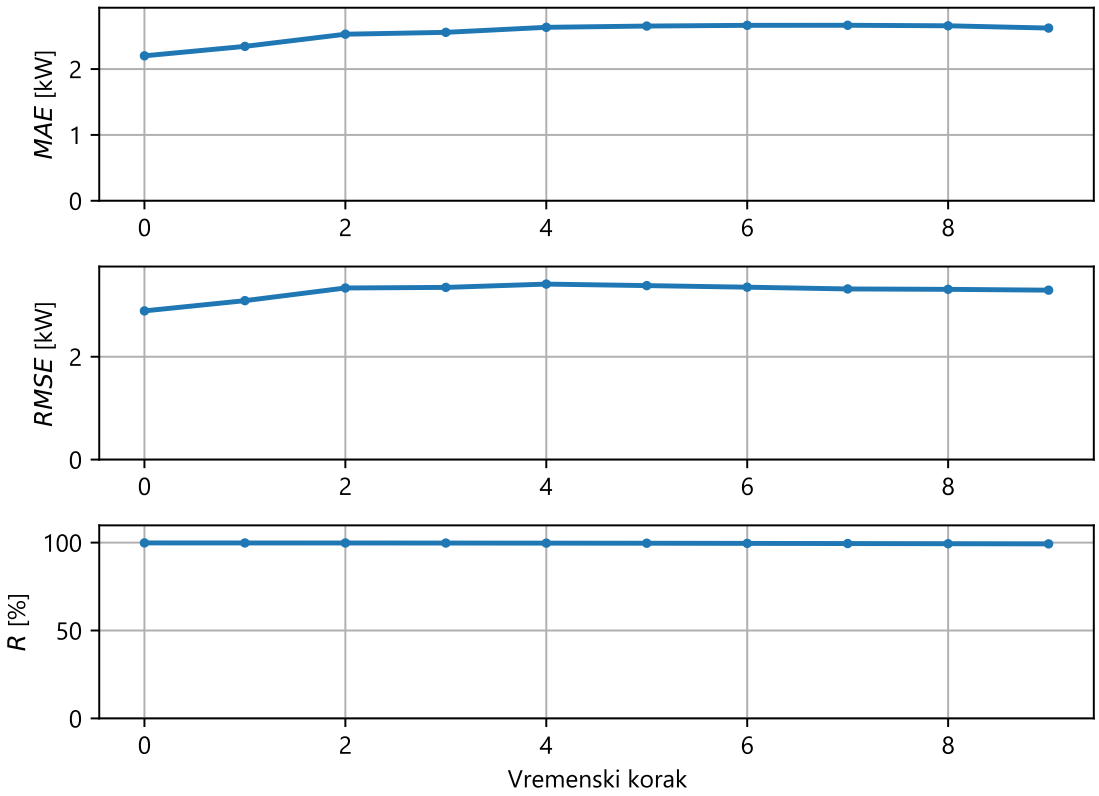

Slika 5.25: *Srednja apsolutna pogreška MAE, korijen srednje kvadratne pogreške RMSE i koeficijent korelacije R za sve pojedine vremenske korake predviđanja u budućnosti za cijeli horizont predviđanja pomoću umjetne neuronske mreže ANN1*

Raspršeni graf koji analizira točnost predviđanja umjetne neuronske mreže ANN1 za svaki pojedini vremenski korak u budućnosti, za sve iteracije, uz prikaz koeficijent korelacije R vidljiv je na slici 5.26. Grafički prikaz istog odnosa veličina za ANN2 i ANN3 vidljiv je na slici P.7 i slici P.8 u prilogu, slijedno. Analizirajući prikazane grafove zaključuje se kako s porastom vremenskog koraka koji se predviđa u budućnosti koeficijent korelacije R pada. Ovo je očekivano jer se pogreška predviđanja povećava s vremenskom udaljenosti od trenutka predviđanja.

Analizirajući statističke indekse pogreške za ocjenu performansi (točnosti) predviđanja i grafičku analizu rezultata može se donijeti generalni zaključak da je umjetna neuronska mreža ANN1, koja predviđa snagu potrošnje električne energije mikromreže, generira točnije prognoze od umjetnih neuronskih mreža ANN2 (profil snage sunčevog zračenja) i ANN3 (profil temperature okoliša). Različita točnost rezultata leži u prirodi izlazne veličine koju predviđaju pojedine umjetne neuronske mreže. Snaga sunčevog zračenja (ANN2) i temperatura okoliša (ANN3) vrlo su nepredvidive meteorološke veličine koje ovise o mnogo drugih meteoroloških čimbenika. Prema tome, prilikom primjene umjetnih neuronskih mreža za predviđanje od iznimne je važnosti pravilno odrediti ulazne veličine (prediktore) o kojima ovisi izlazna veličina.

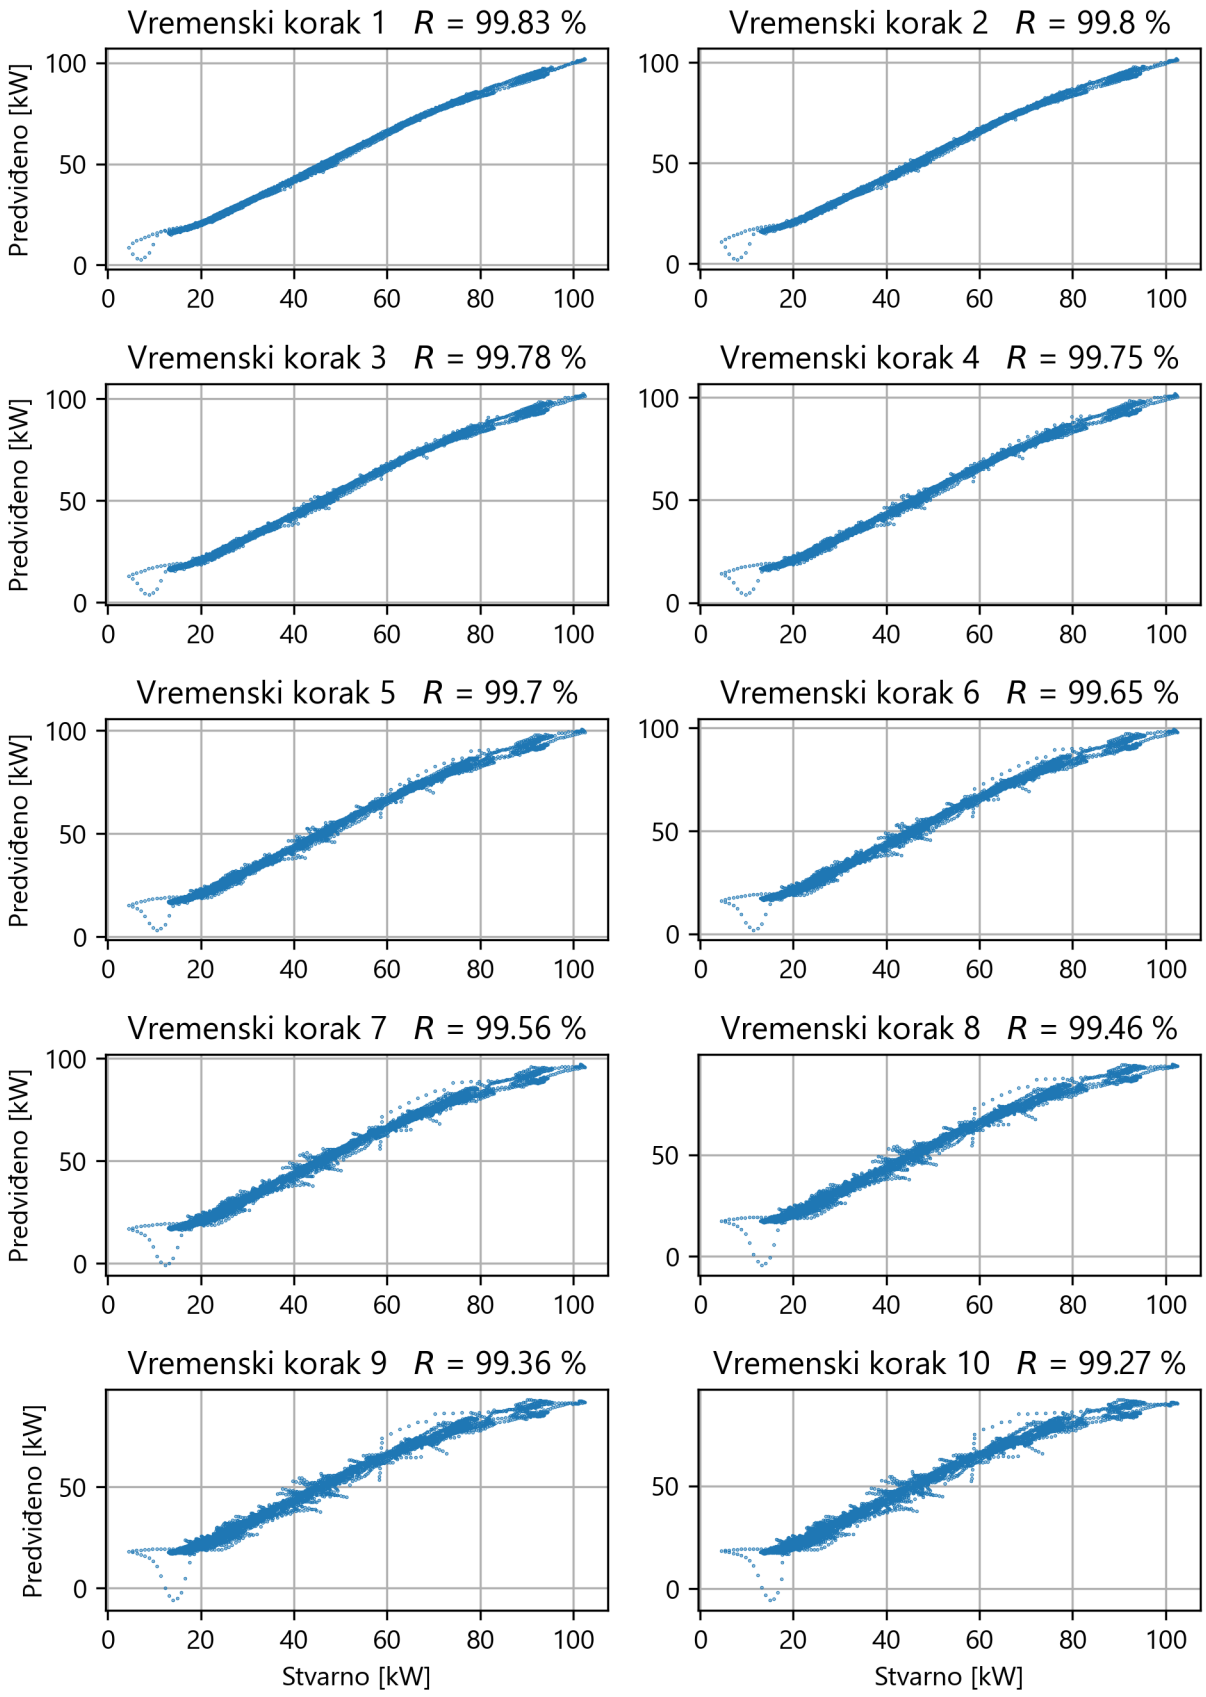

Slika 5.26: *Odnos predviđene i stvarne snage potrošnje električne energije mikromreže pomoću umjetne neuronske mreže ANN1 za svaki vremenski korak predviđanja u budućnosti na cijelom testnom skupu*

5.4. Rezultati kratkoročnog planiranja pogona testne mikromreže

Razvijeni dvoslojni adaptivni sustav upravljanja energijom primijenjen je na planiranje kratkoročnog planiranja pogona testne mikromreže za jedan karakterističan dan. Vrednovanje je podijeljeno na tri dijela (analize). U prvom dijelu analizira se utjecaj dodatnih (virtualnih) prihoda/troškova funkcije cilja optimizacijskog problema višeg sloja sustava upravljanja energijom na kratkoročno planiranje pogona testne mikromreže pomoću 4 simulacijska podslučaja. U drugom dijelu se vrednovao utjecaj optimizacijskog okvira na kratkoročno planiranje pogona testne mikromreže pomoću tri simulacijska podslučaja. U zadnjem je dijelu izvršena analiza osjetljivosti funkcije cilja optimizacijskog problema višeg sloja sustava upravljanja energijom na postavke elemenata testne mikromreže.

Rezultati simulacija mogu se prikazati na velik broj načina s obzirom na aspekt promatranja. Zbog ograničenosti prostora u nastavku su prikazani samo rezultati neophodni za vrednovanje razvijenog dvoslojnog sustava upravljanja energijom za pojedine analize i studijske podslučajeve.

5.4.1. Utjecaj dodatnih (virtualnih) prihoda/troškova funkcije cilja višeg sloja sustava upravljanja energijom na kratkoročno planiranje pogona testne mikromreže

Kako se funkcija cilja optimizacijskog problema višeg sloja sustava upravljanja energijom (prikazana u izrazu 4-59) sastoji od više članova koji se mogu podijeliti na pogonske i dodatne (virtualne) prihode i troškove, moguće je analizirati utjecaj pojedinih članova, posebice dodatnih (virtualnih) troškova, na kratkoročno planiranje pogona mikromreže. Mogućnost rada u mrežnom i izoliranom (otočnom) pogonu jedno je od osnovnih obilježja mikromreže, stoga se u ovom potpoglavlju izvršava vrednovanje za četiri simulacijska podslučaja poredana po složenosti funkcije cilja i pogonskim prilikama:

- **1. podslučaj:** Umrežen pogon testne mikromreže uz funkciju cilja koja sadrži sljedeću kombinaciju članova pogonskih i dodatnih (virtualnih) prihoda/troškova:
  - Trošak preuzimanja električne energije iz nadređene elektroenergetske mreže;
  - Prihod od predaje električne energije u nadređenu elektroenergetsku mrežu;
  - Trošak novoangažirane snage u horizontu planiranja;
  - Ukupni trošak rada upravljivog generatora;
  - Trošak upravljanja potrošnjom statički upravljivog trošila.
- **2. podslučaj:** Umrežen pogon testne mikromreže uz funkciju cilja koja sadrži sve članove funkcije cilja prisutne u 1. podslučaju uz dodatni član koji valorizira pohra-

njenu energiju u baterijskom sustavu pohrane energije;

- **3. podslučaj (referentni): Umrežen pogon testne mikromreže uz funkciju cilja koja sadrži sve članove funkcije cilja prisutne u 2. podslučaju uz dodatni član koji računa ukupni trošak degradacije baterijskog sustava pohrane energije**;
- **4. podslučaj:** Umreženo/izolirani (otočni) pogon testne mikromreže uz funkciju cilja koja sadrži sve članove funkcije cilja prisutne u 3. podslučaju.

U svim promatranim podslučajima ne nalazi se trošak upravljanja potrošnjom dinamički upravljivog trošila, definiran izrazom 4-59, budući da ova vrsta trošila nije modelirana u testnoj mikromreži. U svim podslučajima nalaze se svi članovi pogonskih prihoda/troškova i troška upravljanja potrošnjom statički upravljivog trošila. Razlog prisutnosti ovog troška u svim podslučajima je što bi uslijed njegovog izbacivanja iz funkcije cilja, rezultat optimizacije bio uvijek maksimalno rasterećenje planiranog profila (prikazanog na slici 5.10) što ne bi predstavljalo dodatni trošak definiran izrazom 5-4. Razlika između 1. i 2. podslučaja je u članu koji valorizira pohranjenu energiju baterijskog sustava pohrane energije. Ovaj član funkcije cilja uključen je radi analize njegovog utjecaja na rad baterijskog sustava pohrane energije, a posljedično i na kratkoročno planiranje pogona testne mikromreže. Navedeno znači da je u 1. simulacijskom podslučaju potrebno eksplicitno definirati stanje napunjenosti baterije na kraju horizonta planiranja ($t = T$) budući da isključenjem člana koji valorizira pohranjenu energiju nema mehanizma koji bi regulirao stanje napunjenosti na kraju horizonta planiranja. To bi gotovo uvijek rezultiralo potpunim pražnjenjem baterije radi ostvarenja najveće uštede ili zarade, a pritom ostavljajući praznu bateriju za buduću upotrebu. U ovom podsimulacijskom slučaju stanje napunjenosti na kraju horizonta planiranja $SOE^{\%}_{T,1}$ se izjednačava sa stanjem napunjenosti na početku horizonta planiranja $SOE^{\%}_{0,1}$ i iznosi 100 %, a definirano je izrazom 5-5. Jednako stanje napunjenosti na početku i na kraju horizonta planiranja postavlja se u svrhu izbjegavanja generiranja dodatne uštede ili prihoda u slučaju različitih stanja napunjenosti na početku i na kraju. Treći podslučaj predstavlja **referentni slučaj** jer sadržava sve članove funkcije cilja defnirane u izrazu 4-59.

U prva tri podslučaja testna mikromreža radi u umreženom načinu rada dok se u 4. podslučaju simulira planirani prekid opskrbe u duljini od 4 sata. Planirani prekid opskrbe simulira se u razdoblju od 13:00 do 17:00 sati. Na kraju, treba naglasiti da se zbog ograničenog prostora za potrebe analize promatranih podslučajeva ne promatraju rezultati optimizacijskog problema nižeg sloja sustava iako je on sastavni dio sustava upravljanja energijom mikromreže.

$$SOE^{\%}_{T,1} = SOE^{\%}_{0,1} = SOE^{\text{init}}_{1} = 100\% \tag{5-5}$$

Prema gore opisanim studijskim podslučajima, u ovom poglavlju se analizira utjecaj modela baterijskog spremnika energije kroz uključivanje odnosno isključivanje članova funkcije cilja višeg sloja sustava upravljanja energijom mikromreže koji se odnose na njega (izuzevši troškove upravljanja statički upravljivog trošila).

Za potrebe analize pojedinih podslučaja optimizacijski postupak izvršit će se na osnovu ulaznih podataka predviđenih za prvi horizont predviđanja (PH_1) odnosno za samo jedan vremenski korak (iteraciju).

Tablica 5.15 prikazuje rezultate kratkoročnog planiranja pogona testne mikromreže dobivene optimizacijskim postupkom. Tablica sadržava vrijednosti funkcije cilja višeg sloja sustava upravljanja energijom mikromreže, neto vrijednosti svih pogonskih i dodatnih (virtualnih) prihoda/troškova za promatrani horizont planiranja i promatrane podslučajeve izražene u kunama (kn). Negativna vrijednost predstavlja gubitak (funkcija cilja) odnosno trošak (član funkcije cilja) dok pozitivna vrijednost predstavlja profit (funkcija cilja) odnosno prihod (član funkcije cilja).

Tablica 5.15: *Vrijednosti funkcije cilja višeg sloja sustava upravljanja energijom i neto vrijednost svih pogonskih i dodatnih (virtualnih) prihoda/troškova za promatrani horizont planiranja i promatrane podslučajeve*

Vrijednost [kn]	**Podslučaj 1**	**Podslučaj 2**	**Podslučaj 3 (referentni)**	**Podslučaj 4**
Funkcija cilja	-173.57	-35.28	-230.47	-354.11
Neto pogonski prihodi/-troškovi	-173.57	-44.26	-158.53	-93.15
Neto dodatni (virtualni) prihodi/troškovi	0	8.98	-71.94	-260.96

Vrijednosti pojedinih članova funkcije cilja (prihodi/troškovi) višeg sloja sustava upravljanja energijom za promatrani horizont planiranja i promatrane podslučajeve prikazani su u tablici 5.16. Sve vrijednosti u tablici 5.16 izražene su u kunama (kn).

Tablica 5.16: *Vrijednosti pojedinih članova funkcije cilja višeg sloja sustava upravljanja energijom za promatrani horizont planiranja i promatrane podslučajeve*

Prihod/trošak [kn]	**Podslučaj 1**	**Podslučaj 2**	**Podslučaj 3 (referentni)**	**Podslučaj 4**
Trošak preuzimanja električne energije od opskrbljivača	216.58	102.55	217.05	132.67
Prihod od predaje električne energije opskrbljivaču	43	58.3	58.51	49.33
Trošak novoangažirane snage	0	0	0	0
Trošak rada upravljivog generatora	0	0	0	9.81
Trošak cikličkog starenja baterijskog sustava pohrane energije	0	0	7.56	96.89
Trošak kalendarskog starenja baterijskog sustava pohrane energije	0	0	140.48	129.71
Vrijednost pohranjene energije baterijskog sustava pohrane energije	0	8.98	76.1	38.4
Trošak rasterećenja statički upravljivog trošila	0	0	0	72.77

Iznosi izmijenjenih energija pojedinih elemenata mikromreže za promatrani horizont planiranja i promatrane podslučajeve prikazani su u tablici 5.17. Svi iznosi u tablici 5.17 izraženi su u kilovatsatima (kWh).

Tablica 5.17: *Iznosi izmijenjenih električnih energija pojedinih elemenata mikromreže za promatrani horizont planiranja i promatrane podslučajeve*

Energija [kWh]	**Podslučaj 1**	**Podslučaj 2**	**Podslučaj 3 (referentni)**	**Podslučaj 4**
Preuzeta električna energija od opskrbljivača	346.18	199.05	312.75	228.41
Predana električna energija opskrbljivaču	108.6	147.22	147.76	124.58
Proizvedena električna energija iz fotonaponskog sustava	848.04	848.04	848.04	848.04
Ispražnjenja električna energija iz baterijskog sustava pohrane energije	55.79	154.13	43.24	120.49
Električna energija utrošena za punjenje baterijskog sustava pohrane energije	87.41	0	2.27	25.4
Proizvedena električna energija iz upravljivog generatora	0	0	0	0.54
Potrošnja električne energije neupravljive (kritične) potrošnje	975.5	975.5	975.5	975.5
Potrošnja električne energije statički upravljivog trošila	48.7	48.7	48.7	42.2
Potrošnja električne energije vremenski odgodivog trošila	29.8	29.8	29.8	29.8

Za potrebe dodatne analize utjecaja dodatnih (virtualnih) članova funkcije cilja definirana su dva pokazatelja, pokazatelj vlastite potrošnje (engl. *Self-consumption index*) i pokazatelj samodostatnosti opskrbe (engl. *Self-sufficiency*) mikromreže. Pokazatelj vlastite potrošnje mikromreže SC_t^{MG} definira se kao postotak vlastite proizvodnje električne energije (unutar mikromreže) koja izravno napaja vlastitu potrošnju mikromreže. Kako vlastita potrošnja mikromreže uvijek postoji (veća od 0), kod računanja pokazatelja vlastite potrošnje mogu se javiti dva karakteristična slučaja:

- kada nema vlastite proizvodnje električne energije (sva električna energija se preuzima od opskrbljivača iz mreže), pokazatelj vlastite potrošnje iznosi $SC_t^{\mathrm{MG}} = 0$ %,
- kada je vlastita potrošnja mikromreže veća od vlastite proizvodnje električne energije,

pokazatelj vlastite potrošnje iznosi $SC_t^{\mathrm{MG}} = 100\ \%$.

U svim ostalim slučajima pokazatelj vlastite potrošnje računa se prema izrazu 5-6.

$$SC_t^{\mathrm{MG}} = \frac{\left[P_t^{crit} + \sum_{l=1}^{L_{\mathrm{stat}}} P_{t,l}^{\mathrm{stat}} + \sum_{l=1}^{L_{\mathrm{shft}}} P_{t,l}^{\mathrm{shft}}\right] + \sum_{bess=1}^{BESS} P_{t,bess}^{\text{ch ac}}}{\sum_{pv=1}^{PV} P_{t,pv}^{\mathrm{AC}} + \sum_{dg=1}^{DG} P_{t,bess}^{\mathrm{DG}}} \cdot 100\% \quad \forall t \in T \tag{5-6}$$

Pokazatelj samodostatnosti opskrbe mikromreže SS_t^{MG} definira se kao postotak vlastite potrošnje električne energije mikromreže opskrbljen vlastitom proizvodnjom. Kako vlastita potrošnja mikromreže uvijek postoji (veća od 0), kod računanja pokazatelja vlastite potrošnje može se javiti karakteristični slučaj kada je vlastita proizvodnja električne energije veća od vlastite potrošnje električne energije. U tom slučaju pokazatelj samodostatnosti opskrbe iznosi $SS_t^{\mathrm{MG}} = 100\ \%$. U ostalim slučajima pokazatelj samodostatnosti opskrbe se računa prema izrazu 5-7.

$$SS_t^{\mathrm{MG}} = \frac{\sum_{pv=1}^{PV} P_{t,pv}^{\mathrm{AC}} + \sum_{dg=1}^{DG} P_{t,bess}^{\mathrm{DG}} + \sum_{bess=1}^{BESS} P_{t,bess}^{\text{disch ac}}}{P_t^{crit} + \sum_{l=1}^{L_{\mathrm{stat}}} P_{t,l}^{\mathrm{stat}} + \sum_{l=1}^{L_{\mathrm{shft}}} P_{t,l}^{\mathrm{shft}}} \cdot 100\% \quad \forall t \in T \tag{5-7}$$

Prije analiziranja rezultata optimizacije za promatrane podslučajeve, rezultati su prikazani i grafički. Slika 5.27 prikazuje tokove snaga u testnoj mikromreži nakon optimizacijskog postupka višeg sloja sustava upravljanja energijom za promatrani horizont planiranja i promatrane podslučajeve. Tokovi snaga u mikromreži prikazani su s aspekta operatora mikromreže. Pozitivne vrijednosti predstavljaju izvore, a negativne vrijednosti potrošače električne energije unutar testne mikromreže. Ovo ujedno znači da u svakom vremenskom koraku površina ispod svakog stupca na strani izvora električne energije (pozitivne vrijednosti) mora biti jednaka površini ispod svakog stupca (negativne vrijednosti) na strani potrošača. Jednakost površina uvjetovana je bilancom tokova snaga u mikromreži, definirana izrazom 4-60. Prema tome, preuzimanje električne energije od opskrbljivača iz nadređene elektroenergetske mreže smatra se izvorom električne energije unutar mikromreže, a predaja električne energije u nadređenu elektroenergetsku mrežu predstavlja potrošnju električne energije unutar mikromreže. Na slici 5.28 prikazani su profili snage preuzimanja odnosno predaje električne energije iz/u nadređenu elektroenergetsku mrežu zajedno s jediničnim troškom/vrijednosti preuzete/predane električne energije opskrbljivaču. Slika 5.29 prikazuje profil punjenja i pražnjenja baterijskog sustava pohrane energije zajedno s trenutnim stanjem napunjenosti baterije (SOE) za promatrani horizont planiranja i promatrane podslučajeve.

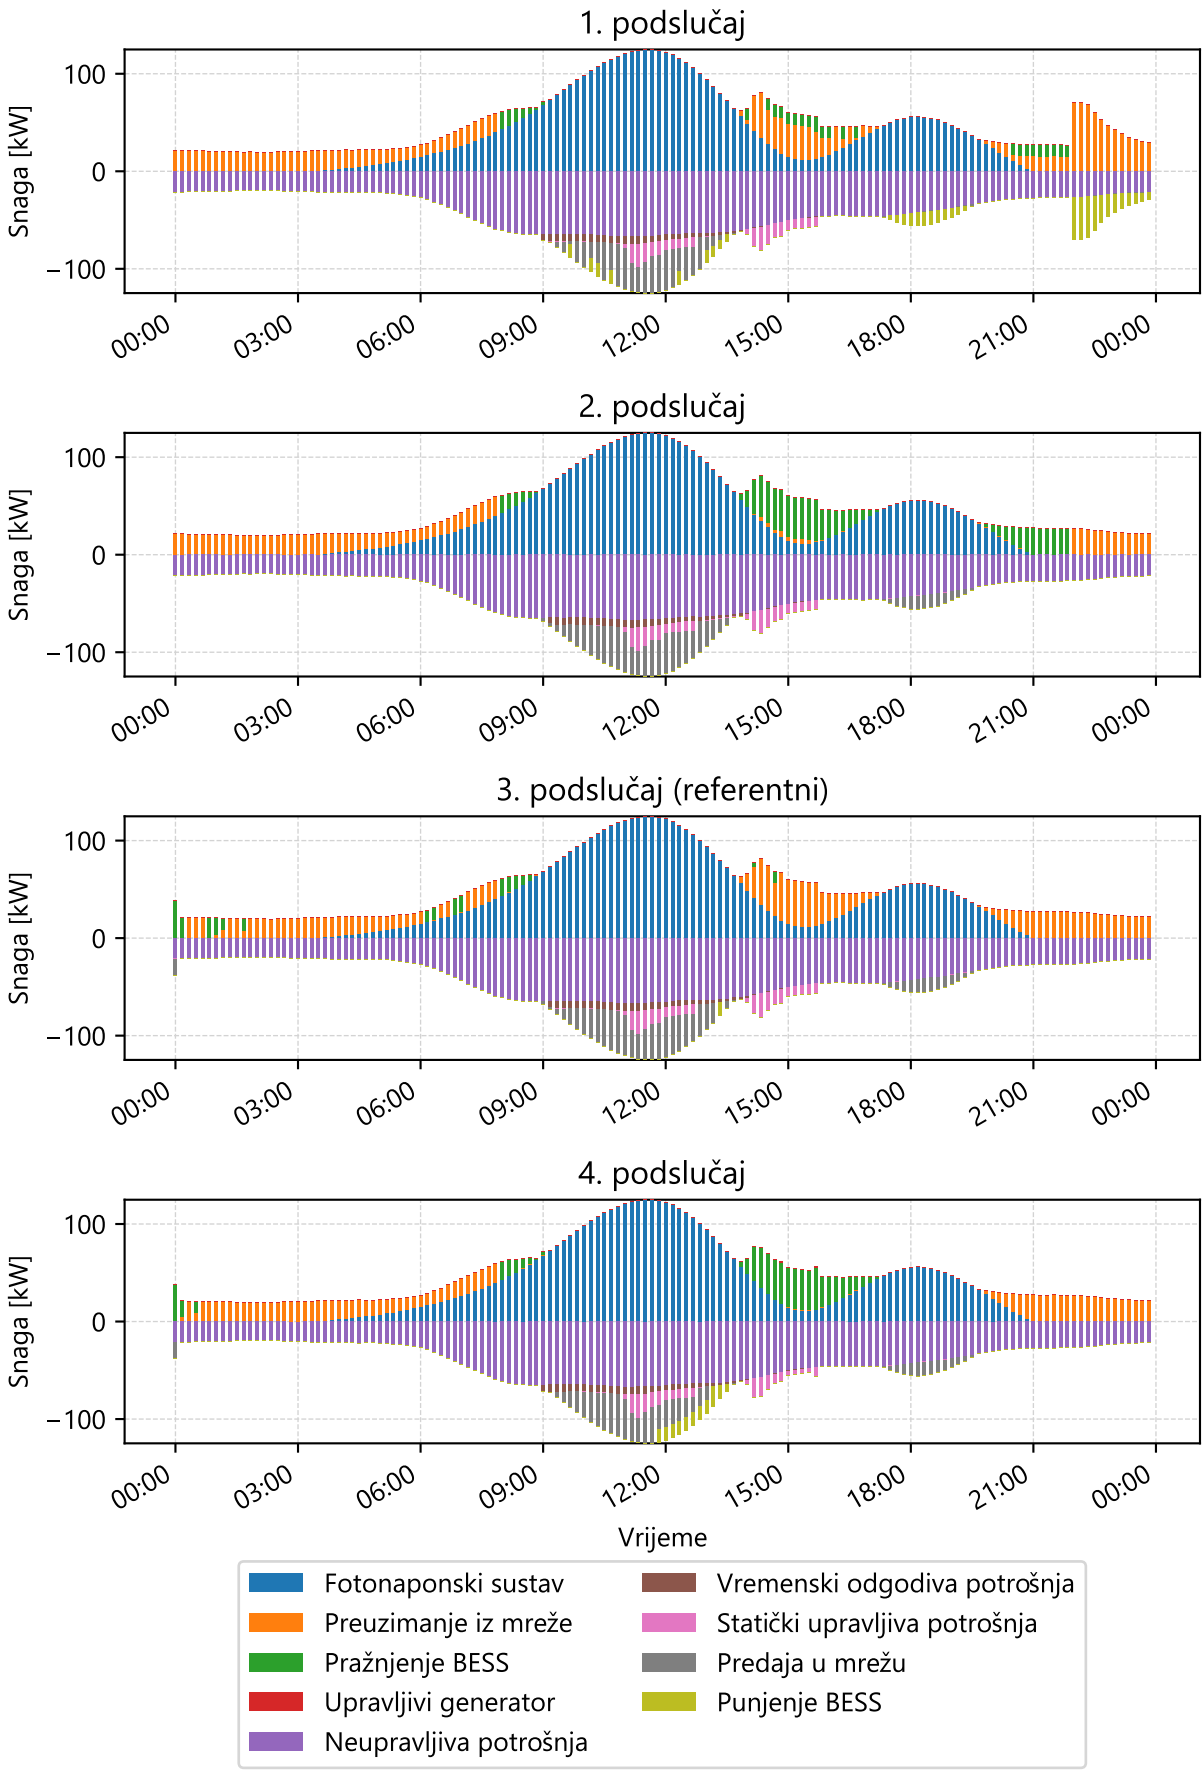

Slika 5.27: *Tokovi snaga u mikromreži u promatranom horizontu planiranja za sva četiri podslučaja*

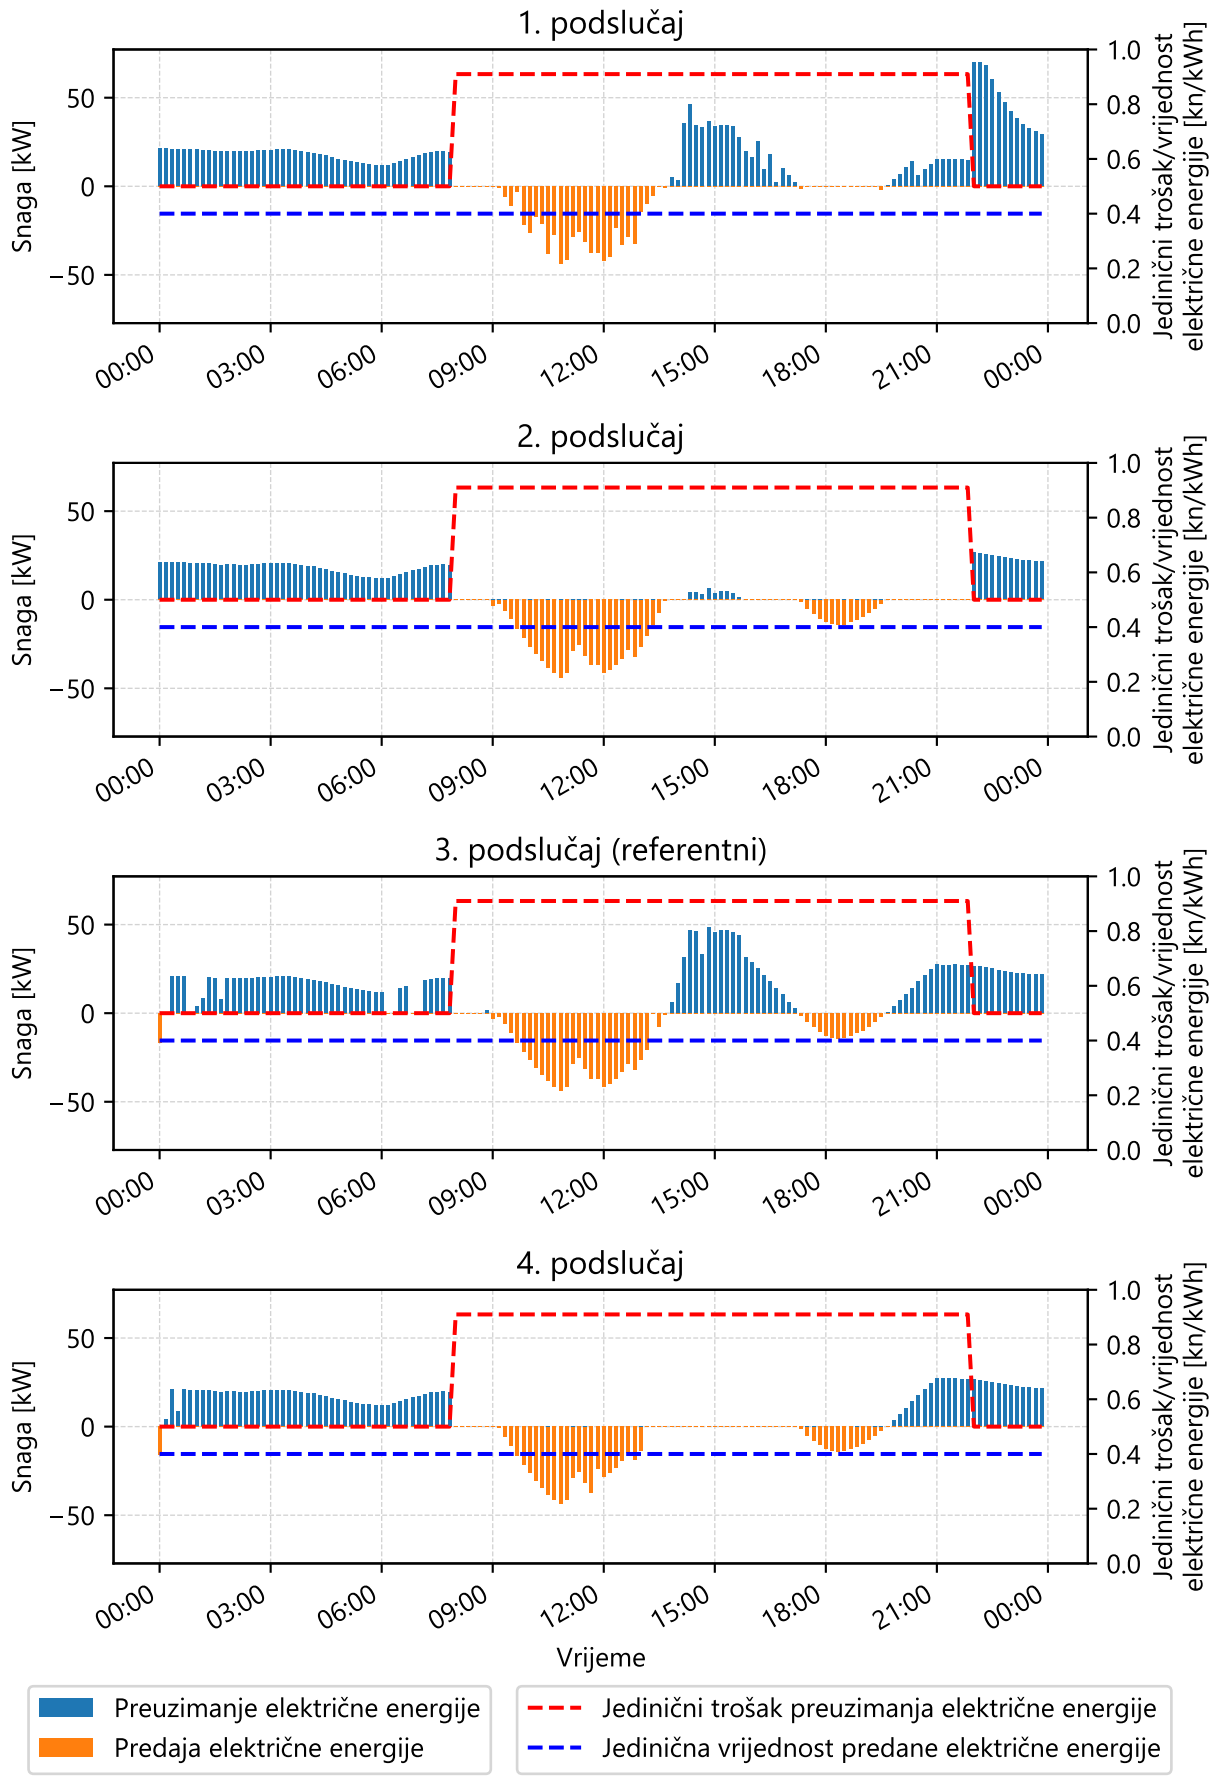

Slika 5.28: *Profil preuzimanja/predaje električne energije iz/u nadređenu elektroenergetsku mrežu u promatranom horizontu planiranja za sva četiri podslučaja*

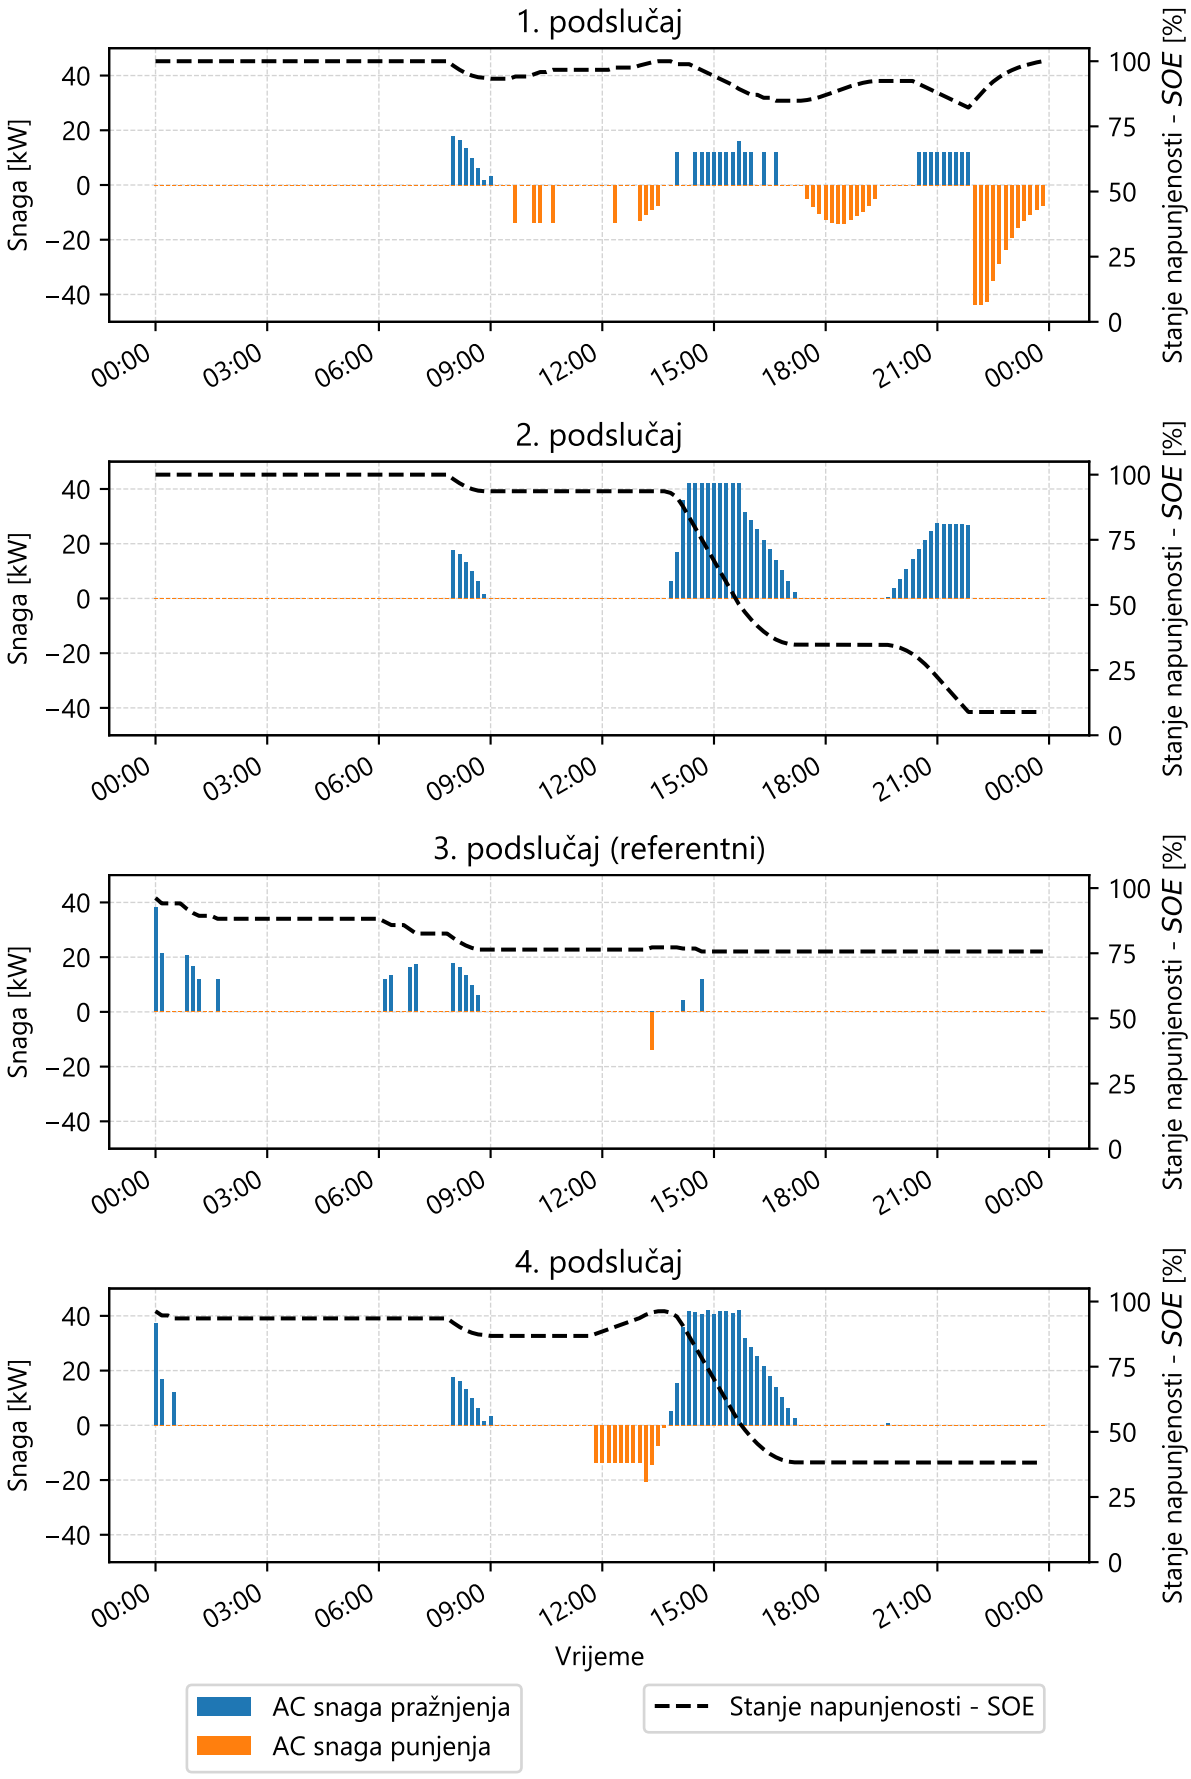

Slika 5.29: *Profil punjenja i pražnjenja baterijskog sustava pohrane energije u promatranom horizontu planiranja za sva četiri podslučaja*

Rezultat planirane odgode potrošnje vremenski odgodivog trošila vidljiv je na slici P.9 u prilogu dok slika P.10 u prilogu prikazuje rezultat rasterećenja statički upravljivim trošilom za promatrane podslučajeve i promatrani horizont planiranja.

Analizirajući rezultate optimizacije, zaključuje se da najveći utjecaj na kratkoročno planiranje pogona testne mikromreže ima baterijski sustav pohrane energije. Ovo se može zaključiti i iz rezultata prikazanih u tablici 5.15 gdje 2. podslučaj rezultira najvećom vrijednošću funkcije cilja (najmanjim gubitkom) i najmanjim pogonskim troškovima. Razlog ovome je isključenje članova funkcije cilja kojim se izračunava trošak degradacije (cikličke i kalendarske) baterijskog sustava pohrane energije koji smanjuje upotrebu baterijskog sustava pohrane energije tijekom promatranog horizonta planiranja. Uspoređujući 2. podslučaj i referentni (3. podslučaj), koji se razlikuju u isključenom odnosno uključenom članu funkcije cilja kojim se izračunava trošak degradacije baterijskog sustava pohrane energije, iz slike 5.29 uočava se puno manja upotreba baterijskog sustava pohrane energije u referentnom (3. podslučaju) u odnosu na 2. podslučaj. Ovo potvrđuju i iznosi ukupne energije dobivene pražnjenjem i uložene tijekom punjenja baterijskog sustava pohrane energije prikazani u tablici 5.17. Razlog malog korištenja i visokog stanja napunjenosti baterijskog sustava pohrane energije u referentnom podslučaju (3. podslučaju) leži u mehanizmu izračuna troška uslijed cikličke i kalendarske degradacije.

Kalendarska degradacija baterijskog sustava pohrane energije penalizira visoko stanje napunjenosti baterije, definirano u izrazu 4-24. Ciklička degradacija baterijskog sustava pohrane energije penalizira cikluse s dubokim pražnjenjem baterije (što rezultira niskim stanjem napunjenosti baterije), vidljivo u izrazu 4-32. Navedenim se dobivaju dva oprečna svojstva koja utječu na rad baterijskog sustava pohrane energije. Analizirajući rezultate prikazane na slici 5.29 i u tablici 5.16 primjećuje se da trošak kalendarskog starenja prevladava i iznosom i načinom planiranja pogona baterijskog sustava pohrane energije (visoko stanje napunjenosti tijekom cijelog promatranog horizonta planiranja).

Uspoređujući 1. i 2. podslučaj, koji se razlikuju samo za isključen odnosno uključen član funkcije cilja koji valorizira pohranjenu energiju u baterijskom sustavu pohrane energije, zamjećuje se velik utjecaj ručnog postavljanja stanja napunjenosti baterije na kraju horizonta planiranja u odnosu na slučaj kada je mehanizam koji regulira stanje napunjenosti definiran u funkciji cilja. U 1. podslučaju uočavaju se znatno viši pogonski troškovi u odnosu na 2. podslučaj uglavnom zbog primoranog punjenja baterijskog sustava pohrane energije s ciljem zadovoljenja ograničenja stanja napunjenosti na kraju horizonta planiranja, definirano izrazom 5-5. Razlog puno nižeg stanja napunjenosti na kraju horizonta u 2. podslučaju u odnosu na stanje napunjenosti u 1. podslučaju je korištenje niže tarife električne energije. Kako vrijednost pohranjene energije u baterijskom sustavu pohrane energije ovisi o

prosječnoj jediničnoj cijeni prilikom preuzimanja energije iz mreže u budućnosti, definirano izrazom 4-34, punjenje baterijskog spremnika energije u 2. podslučaju se očekuje u horizontu planiranja na čijem kraju se mijenja tarife iz niže u višu (u 8:00 sati sljedećeg dana), čime se povećava vrijednost pohranjene energije u baterijskom sustavu pohrane energije.

Prema gore navedenom, može se zaključiti da razina modela baterijskog sustava pohrane energije omogućuje operatoru (i/ili vlasniku mikromreže), vođenje različitih strategija s obzirom na pogon baterijskog sustava pohrane energije, a i same mikromreže. Isključenjem valorizacije pohranjene energije u baterijskom sustavu pohrane energije i postavljanje ograničenja stanja napunjenosti na kraju horizonta planiranja postiže se potpuno napunjena baterija koja će biti spremna za korištenje u sljedećem razdoblju, što ne mora nužno biti optimalna odluka jer kraj horizonta planiranja ovisi o trenutnoj iteraciji optimizacijskog postupka. Uključenjem troškova degradacije baterijskog sustava pohrane energije omogućuje se produljenje životnog vijeka opreme, no u isto vrijeme se generiraju i veći pogonski troškovi mikromreže.

Analizirajući rezultate prikazane na slici 5.27 vidi se da u prva tri podslučaja nije planirana proizvodnja električne energije iz upravljivog generatora upravo zbog visokog jediničnog troška goriva prikazanog u tablici 5.11. U četvrtom slučaju vidi se planiranje rada upravljivog generatora tijekom izoliranog (otočnog) pogona s iznosom proizvodnje od 0.54 kWh. Manjak električne energije potreban za napajanje vlastite potrošnje tijekom izoliranog (otočnog) pogona (od 13:00 do 17:00 sati) većinom je zadovoljio baterijski sustav pohrane energije jer je ekonomski isplativiji od korištenja upravljivog generatora prvenstveno zbog visokog troška goriva. Iako upravljivi generator u promatranom podslučaju nije korišten u velikoj mjeri za opskrbu vlastite potrošnje mikromreže, on omogućuje dodatni (rezervni) sustav napajanja u slučaju manjka električne energije, a posebice u slučaju velike ispražnjenosti baterijskog sustava pohrane energije zbog čega nije dostupan za opskrbu vlastite potrošnje.

Promotre li se troškovi za novoangažiranu snagu u tablici 5.16, uočava se njihova odsutnost u svim promatranim podslučajevima. Njihova odsutnost ne znači nužno da nemaju utjecaj na kratkoročno planiranje pogona mikromreže. Utjecaj ovog člana funkcije cilja na pogon se vidi kod svih promatranih podslučajeva na slici 5.28 koja prikazuje profil razmjene energije s elektroenergetskom mrežom. Maksimalna snaga preuzimanja električne energije iz nadređene elektroenergetske mreže u nijednom trenutku promatranog horizonta planiranja za sve promatrane slučajeve ne prelazi iznos od 70.2 kW, što odgovara iznosu povijesne vrijednosti najveće angažirane snage $P_m^{\text{grid peak}}$ u tekućem obračunskom razdoblju m. Vidljiv utjecaj ovog člana funkcije cilja vidi se za 1. podslučaj na slici 5.28 gdje je snaga preuzimanja električne energije iz nadređene elektroenergetske mreže vidno ograničena u razdoblju od 22:10 do 22:20 sati u kojima je iznos snage jednak 70.2 kW. Razlog nepostojanja troška

novoangažirane snage leži u velikom jediničnom trošku za angažiranu snagu u iznosu od 38.5 kn/kW, jer je ekonomski isplativije ograničiti snagu preuzimanja električne energije iz nadređene elektroenergetske mreže na manju ili jednaku vrijednost od 70.2 kW, nego angažirati dodatnu snagu.

Analizirajući upravljanje vlastitom potrošnjom električne energije testne mikromreže, vremenski odgodivo trošilo se koristilo u sva četiri promatrana podslučaja s tim da u 1. i 4. podslučaju planirana odgoda iznosi 6 vremenskih koraka (1 sat), dok u 2. i 3. podslučaju planirana odgoda iznosi 7 vremenskih koraka (1:10 sati), što je vidljivo i na slici P.9 u prilogu. Ukupna isporučena energija vremenski odgodivom trošilu odgovara planiranoj potrošnji što je i vidljivo u tablici 5.17. Rasterećenje statički upravljivim trošilom korišteno je jedino u 4. podslučaju u razdoblju kada je testna mikromreža u izoliranom (otočnom) pogonu u odnosu na nadređenu elektroenergetsku mrežu što je vidljivo na slici P.10 u prilogu. Prema rezultatima prikazanim u tablici 5.17 vidi se kako statički upravljivom trošilu u 4. podslučaju nije isporučeno ukupno 6.5 kWh električne energije. Prema tome zaključuje se da je ekonomski isplativije koristiti rasterećenje statički upravljivim trošilima, nego koristiti upravljivi generator bez obzira što je trošak upravljanja potrošnjom statički upravljivog trošila visok.

Ako se promotre pokazatelj vlastite potrošnje i pokazatelj samodostatnosti opskrbe mikromreže prikazani na slici 5.30 vidi se kako tijekom promatranog horizonta planiranja oba pokazatelja imaju visoku razinu za sve promatrane podslučajeve zahvaljujući proizvodnji iz fotonaponskog sustava. Razlike nastaju jedino kod korištenja upravljivih elemenata mikromreže (baterijski sustav pohrane energije, upravljiva trošila i upravljivi generator). Pokazatelj vlastite potrošnje kod svih promatranih podslučajeva u razdobljima od 00:00 do 03:00 sati i 21:00 do 24:00 sati iznosi 0 jer nema vlastite proizvodnje električne energije. Pokazatelj samodostatnosti opskrbe u 4. podslučaju u razdoblju izoliranog (otočnog) pogona mikromreže očekivano iznosi 100 %.

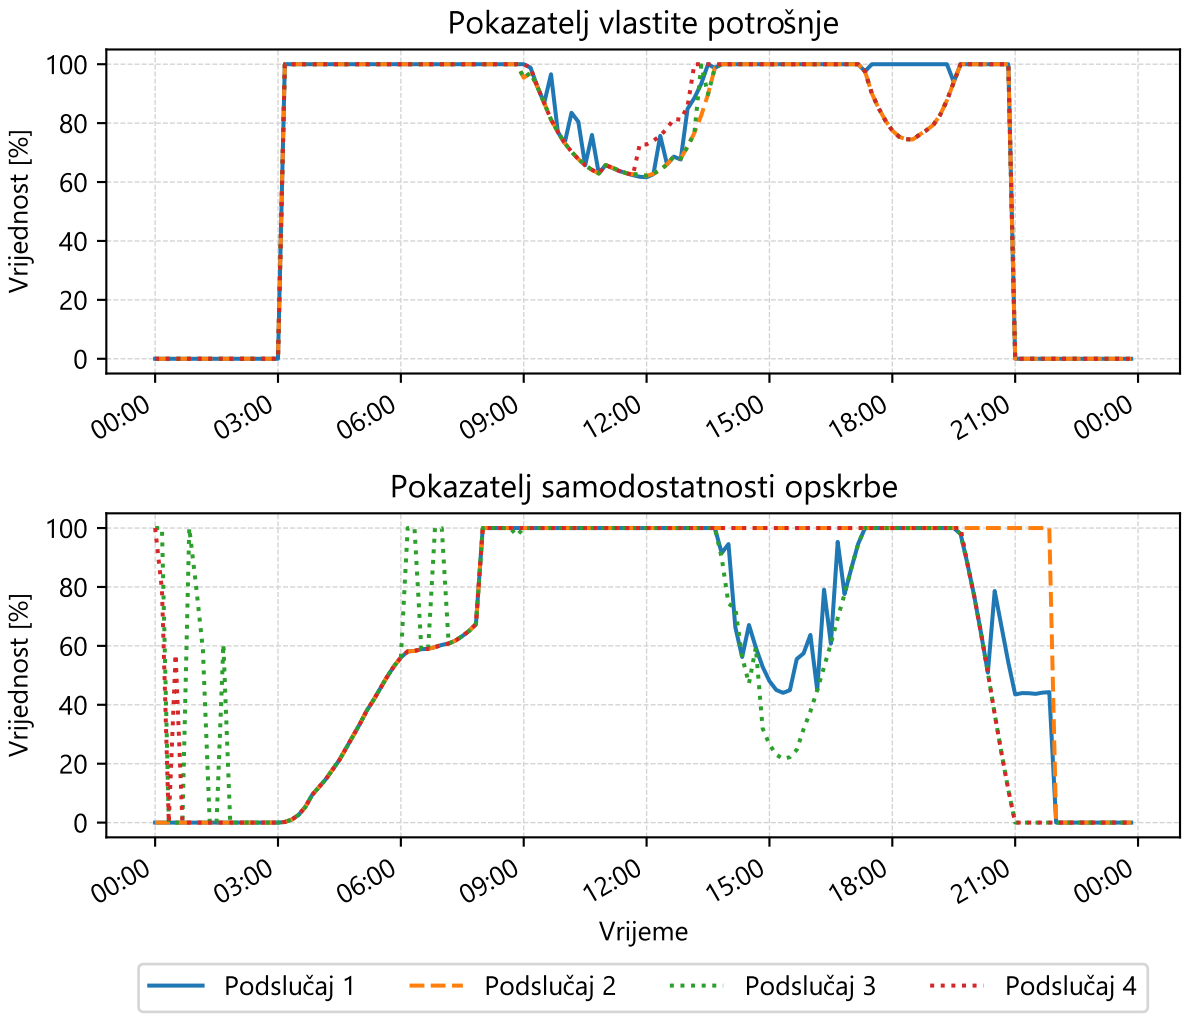

Slika 5.30: *Pokazatelj vlastite potrošnje i pokazatelj samodostatnosti opskrbe u promatranom horizontu planiranja za sva četiri podslučaja*

5.4.2. Utjecaj optimizacijskog okvira na kratkoročno planiranje pogona testne mikromreže

Kako se razvijeni sustav upravljanja energijom sastoji od dva međusobno povezana sloja (optimizacijska problema) različitih karakteristika u ovom poglavlju se analizira svojstvo adaptivnosti kratkoročnim planiranjem pogona testne mikromreže za promatrani dan. Ulazni parametri u optimizacijske probleme (slojeve) sustava upravljanja energijom predstavljaju rezultate predviđanja pomoću umjetnih neuronskih mreža opisanih u poglavlju 5.3 dok se za profil snage sunčevog zračenja i temperature okoliša koriste predviđanja GFS servisa opisan u poglavlju 4.8.1. Usporedba predviđanja ulaznih parametara pomoću različitih metoda korištenih u pojedinim slojevima sa stvarnim mjerenjima prikazane su na slici 5.31. Kako se ulazni parametri za viši sloj predviđaju u svakoj iteraciji optimizacije, na slici 5.31 prikazani su iznosi samo za prvi korak u budućnosti (horizont upravljanja) radi bolje pre-

glednosti. Na slici se uočava razlika iznosa predviđenih ulaznih parametara po pojedinim slojevima zbog kojih se očekuje prilagodba (adaptacija) planiranja kratkoročnog pogona testne mikromreže po pojedinim iteracijama optimizacije. Najveća pogreška u predviđanju, a time i najveći utjecaj na kratkoročno planiranje pogona testne mikromreže, prisutna je kod profila snage sunčevog zračenja o kojemu proizvodnja iz fotonaponskog sustava najviše ovisi. Ovo će rezultirati manjkom ili viškom proizvedene električne energije iz fotonaponskog sustava tijekom promatranog horizonta planiranja koji će za rezultat imati adaptaciju kratkoročnog planiranja pogona testne mikromreže po pojedinim slojevima sustava upravljanja energijom. Profili predviđanja temperature okoliša i snage potrošnje mikromreže većinom se podudaraju sa stvarnim mjerenjima što će imati manji utjecaj na adaptiranje kratkoročno planiranje pogona testne mikromreže.

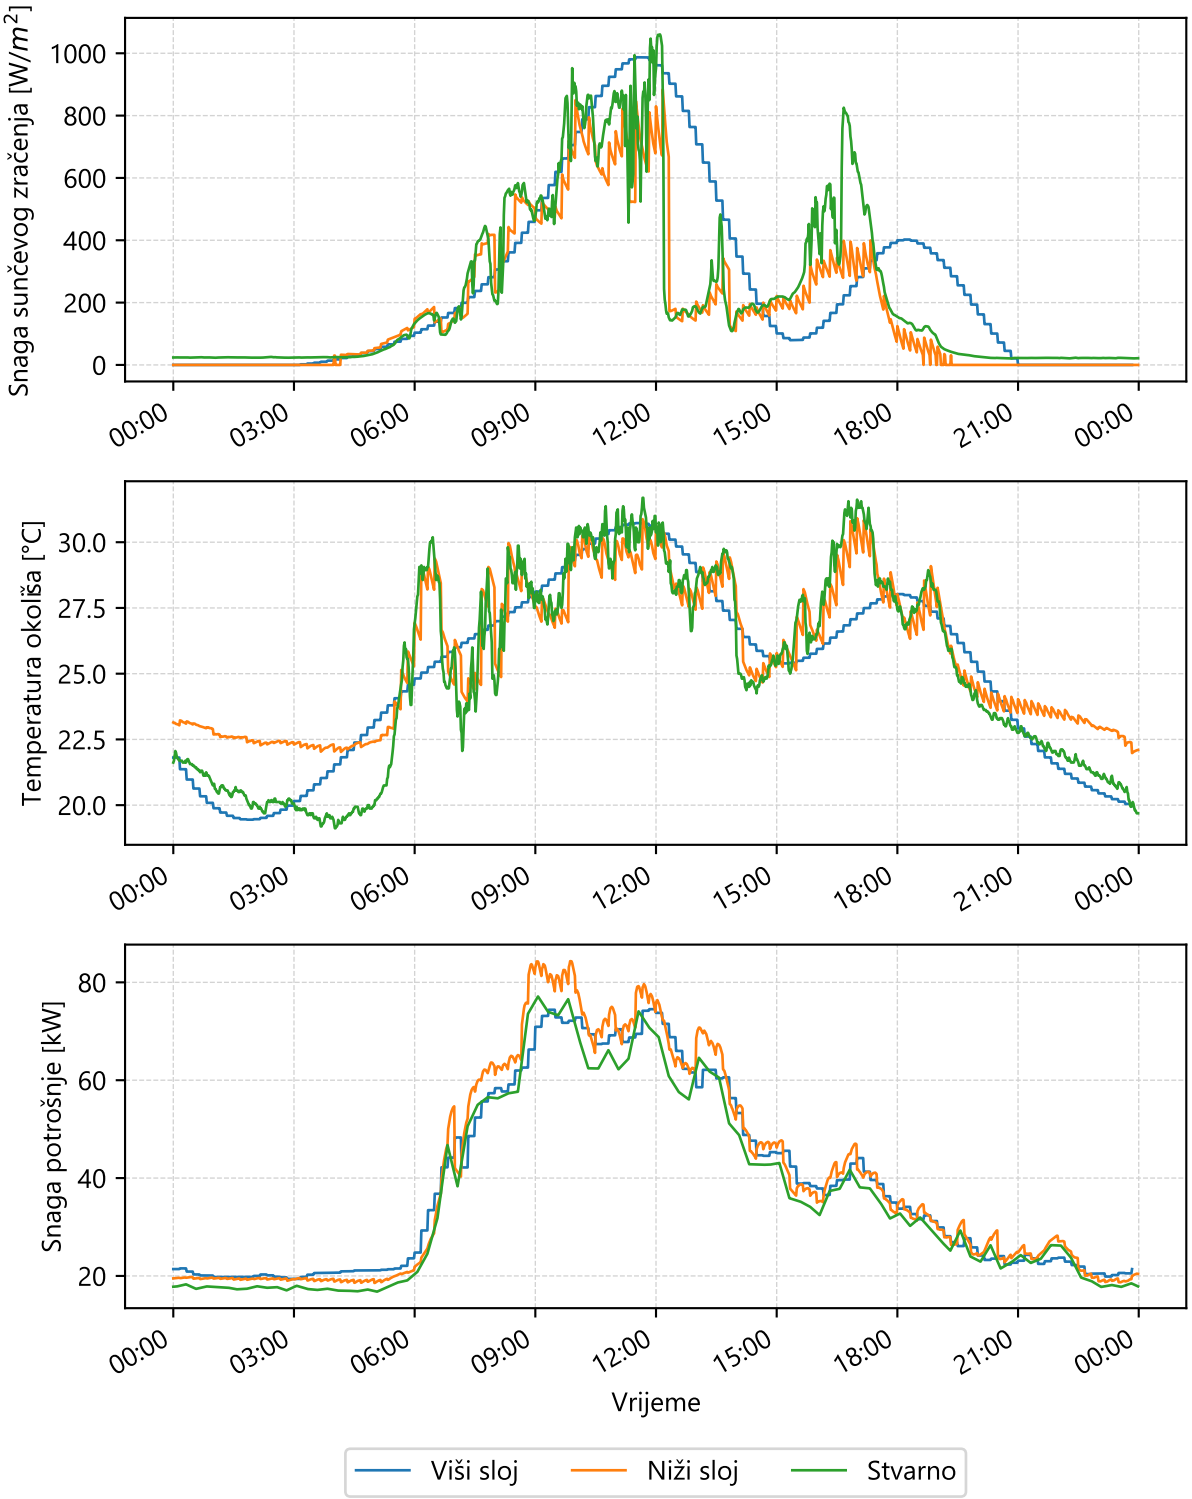

Slika 5.31: *Usporedba predviđanja ulaznih parametara u optimizacijske probleme (slojeve) sa stvarnim mjerenjima*

Adaptivnost razvijenog sustava upravljanja energijom mikromreže vrednovan je u dva koraka. U prvom se koraku adaptivnost vrednuje kroz analizu grafičkih rezultata za karakteristične veličine prilikom kratkoročnog planiranja pogona testne mikromreže pomoću razvijenog dvoslojnog adaptivnog sustava upravljanja energijom mikromreže. Navedeno predstavlja

referentni slučaj koji će imati oznaku podslučaj 3.1, a ujedno predstavlja i 3. podslučaj u poglavlju 5.4.1. U drugom koraku se vrednuje utjecaj optimizacijskog okvira na kratkoročno planiranje pogona testne mikromreže pomoću tri inačice referentnog slučaja:

- **Podslučaj 3.1 (referentni):** Razvijeni dvoslojni sustav upravljanja energijom uz korištenje strategije pomičnog horizonta s korektivnim djelovanjem (*online* optimizacija) i s ulaznim prognozama za oba sloja,
- **Podslučaj 3.2:** Sustav upravljanja energijom samo s višim slojem uz korištenje strategije pomičnog horizonta (*online* optimizacija) i s ulaznim prognozama samo iz višeg sloja,
- **Podslučaj 3.3:** Sustav upravljanja energijom samo s višim slojem i *offline* optimizacijom.

Podslučaj 3.1 predstavlja referentni slučaj koji koristi razvijeni dvoslojni adaptivni sustav upravljanja energijom mikromreže razvijen u sklopu ove disertacije. Podslučaj 3.2 predstavlja sustav upravljanja energijom koji koristi samo viši sloj sustava upravljanja energijom iz podslučaja 3.1 (referentni) dok podslučaj 3.3 predstavlja sustav upravljanja energijom iz podslučaja 3.2, ali bez korištenja strategije pomičnog horizonta odnosno bez *online* optimizacijskog okvira.

Na početku se prikazuju rezultati kratkoročnog planiranja pogona mikromreže za referentni slučaj (podslučaj 3.1). Kako se optimizacijski postupak ponavlja za svaki vremenski korak, nije praktično prikazati rezultate kratkoročnog planiranja za svaku iteraciju. Zbog toga se na slikama koje prikazuju rezultate dobivene pomoću višeg sloja sustava upravljanja energijom prikazuju rezultati za svakih 2 sata (12 vremenskih koraka) radi bolje preglednosti. Rezultati za niži sloj sustava upravljanja energijom prikazani su u potpunosti jer je njihov horizont planiranja jednak horizontu upravljanja višeg sloja sustava upravljanja energijom, koji iznosi jedan vremenski korak, stoga se oni mogu prikazati slijedno.

Na slici 5.32 prikazan je profil preuzimanja/predaje električne energije iz/u nadređenu elektroenergetsku mrežu (opskrbljivaču) u promatranom horizontu planiranja za referentni slučaj (podslučaj 3.1). Pozitivne vrijednosti predstavljaju preuzimanje električne energije iz nadređene elektroenergetske mreže dok negativne vrijednosti predstavljaju predaju električne energije u nadređenu elektroenergetsku mrežu. Na slici se nalaze dvije vrste profila. U prvu vrstu pripadaju profili planirane snage razmjene između testne mikromreže i nadređene elektroenergetske mreže određeni optimizacijskim postupkom za svakih 2 sata (12 vremenskih koraka) dobiveni pomoću višeg sloja sustava upravljanja energijom, a označeni su oznakom $t + h$ gdje h predstavlja višekratnik sata. Drugu vrstu predstavlja profil razmjene snage dobiven kao rezultat optimizacijskog postupka nižeg sloja sustava upravljanja

energijom (zelena boja). Adaptivnost razvijenog dvoslojnog sustava upravljanja energijom vidi se na slici 5.32 na dva načina, kroz promjenu profila planirane razmjene snage između testne mikromreže i nadređene elektroenergetske mreže tijekom promatranog horizonta planiranja dobivenih pomoću višeg sloja sustava upravljanja energijom i kroz profil razmjene snage između mikromreže i nadređene elektroenergetske mreže dobivenog pomoću nižeg sloja sustava upravljanja energijom. Razlog promjena planiranih profila razmjene energije tijekom promatranog horizonta planiranja dobivenih pomoću višeg sloja sustava upravljanja energijom pripisuje se osvježavanju predviđenih profila ulaznih parametara u optimizacijski problem tijekom svake iteracije dobivenih pomoću metoda opisanih u poglavlju 4.8.1. Profil razmjene energije dobiven nižim slojem sustava upravljanja energijom također je rezultat osvježavanja predviđenih profila ulaznih parametara u optimizacijski problem dobivenih pomoću metoda opisani u poglavlju 4.8.2 te varijabli odluka (referentnih vrijednosti) za upravljive elemente mikromreže dobivenih pomoću višeg sloja sustava upravljanja energijom za sljedeći horizont upravljanja. Treba naglasiti kako početno stanje sustava svake iteracije korišteno kod višeg sloja sustava upravljanja energijom ovisi o stanju na kraju horizonta planiranja nižeg sloja sustava upravljanja energijom što je označeno točkama na slici 5.32.

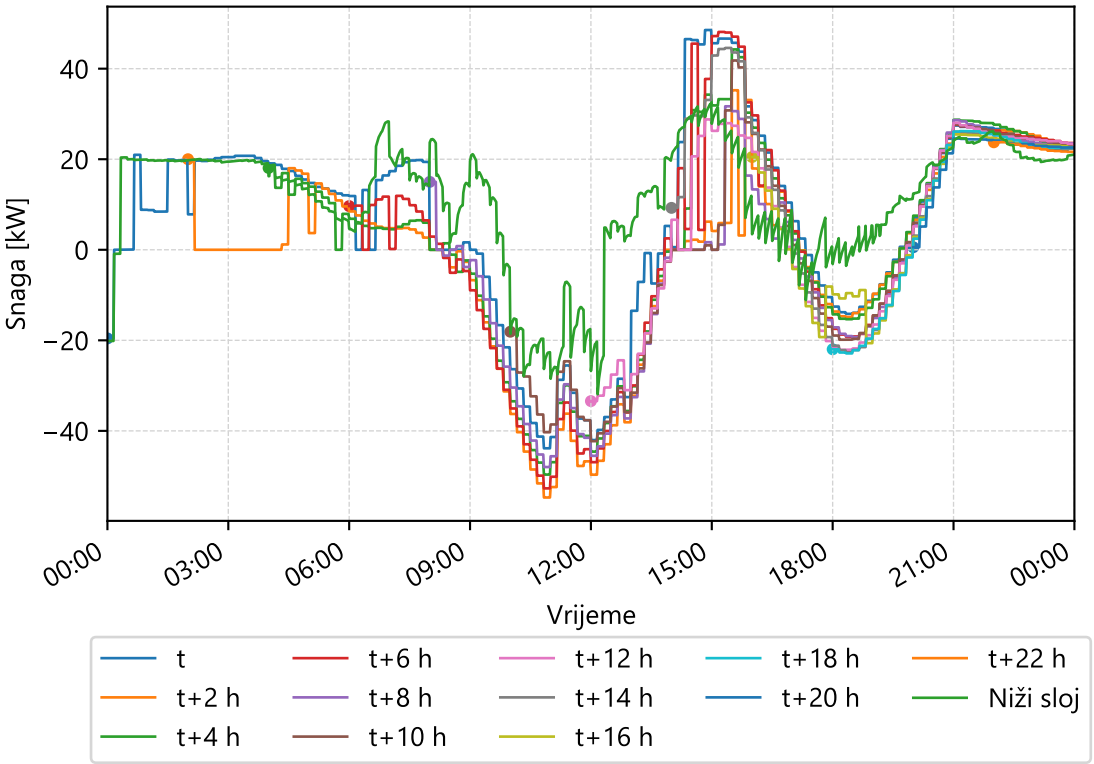

Slika 5.32: *Profil snage preuzimanja i predaje električne energije iz/u nadređenu elektroenergetsku mrežu tijekom promatranog horizonta planiranja za različite iteracije kratkoročnog planiranja pogona testne mikromreže u referentnom slučaju*

Profil snage punjenja i pražnjenja te stanje napunjenosti baterijskog sustava pohrane energije tijekom promatranog horizonta planiranja prikazan je na slici 5.33. Kao i kod profila preuzimanja/predaje električne energije iz/u nadređenu elektroenergetsku mrežu (opskrbljivaču), na slici 5.33 javlja se razlika između profila planiranog rada baterijskog sustava pohrane energije dobivenih pomoću višeg sloja sustava upravljanja energijom i profila rada baterijskog sustava pohrane energije dobivenog pomoću nižeg sloja sustava upravljanja energijom tijekom promatranog horizonta planiranja. Adaptivnost se opet ogleda kroz osvježavanje prognoza u svakoj iteraciji optimizacijskog postupka izvršenog višim i nižim slojem sustava upravljanja energijom mikromreže.

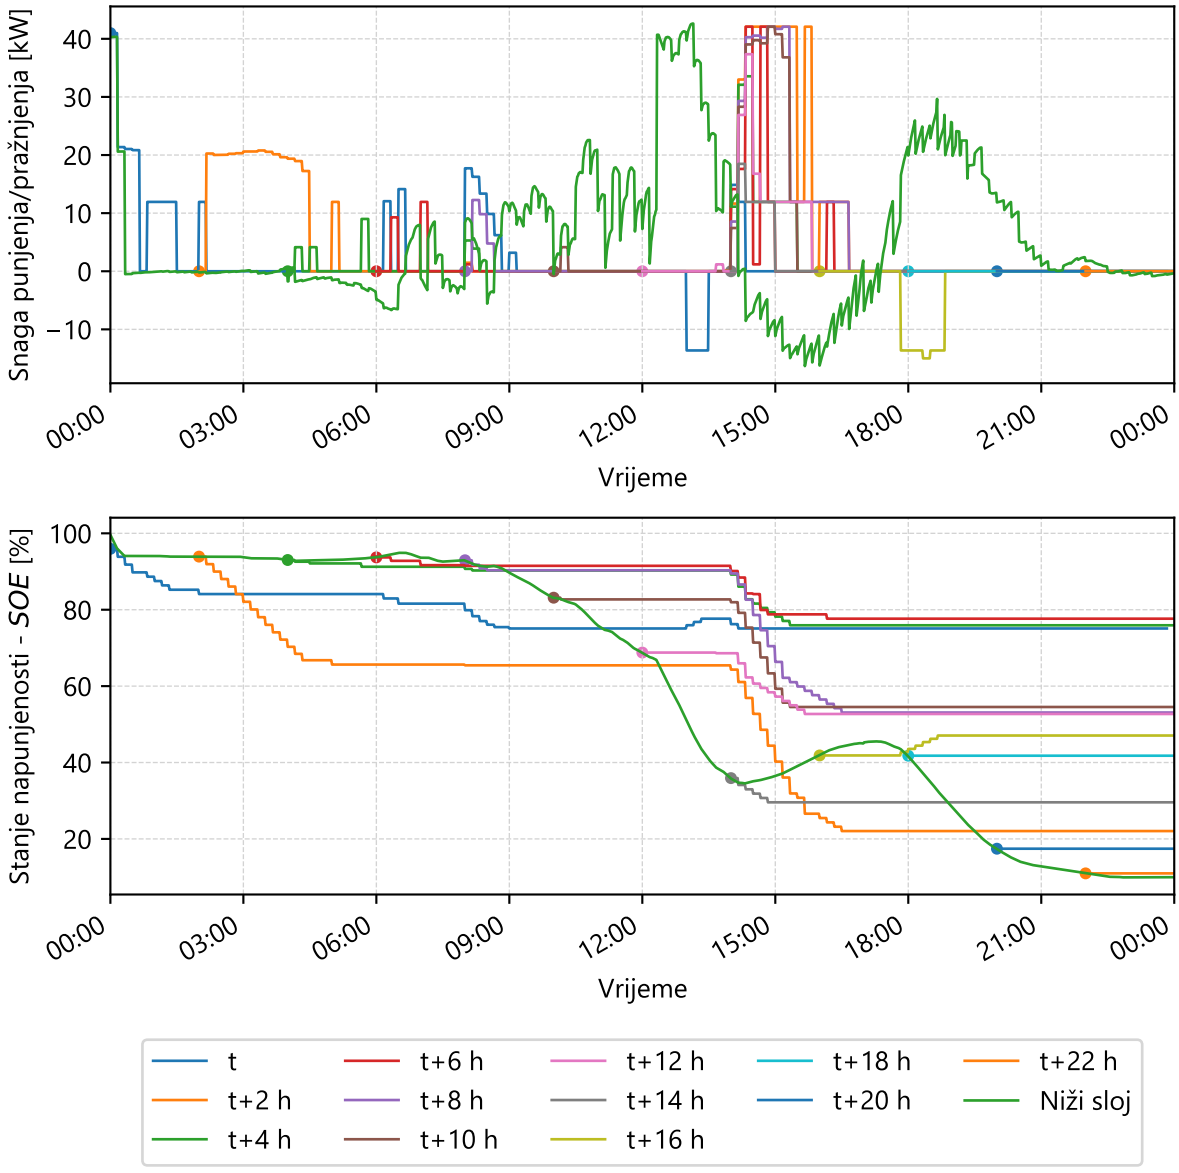

Slika 5.33: *Profil snage punjenja i pražnjenja baterijskog sustava pohrane energije tijekom promatranog horizonta planiranja za različite iteracije kratkoročnog planiranja pogona mikromreže u referentnom slučaju*

Kod profila snage sunčevog zračenja prikazanog na slici 5.31 se vide tri karakteristična razdoblja u promatranom horizontu predviđanja zbog kojih dolazi do potrebe za adaptacijom kratkoročnog planiranja pogona mikromreže po pojedinim slojevima:

- U razdoblju od 12:10 do 14:40 sati snaga sunčevog zračenja predviđena za viši sloj sustava upravljanja energijom veća je od snage sunčevog zračenja predviđene za niži sloj sustava upravljanja energijom;
- U razdoblju od 14:40 do 17:20 sati snaga sunčevog zračenja predviđena za niži sloj sustava upravljanja energijom veća je od snage sunčevog zračenja predviđene za viši sloj sustava upravljanja energijom;
- U razdoblju od 17:20 do 20:50 sati snaga sunčevog zračenja predviđena za viši sloj sustava upravljanja energijom veća je od snage sunčevog zračenja predviđene za niži sloj sustava upravljanja energijom.

Utjecaj ova tri razdoblja vidi se na slikama 5.32 i 5.33. U prvom karakterističnom razdoblju promatranja, manjak energije koji je nastao manjom proizvodnjom električne energije iz fotonaponskog sustava od planirane u višem sloju se pokrio korektivnim mjerama kroz manju predaju električnu energiju u nadređenu elektroenergetsku mrežu i kroz povećanje snage pražnjenja baterijskog sustava pohrane energije. U drugom karakterističnom razdoblju promatranja višak energije koji je nastao većom proizvodnjom električne energije iz fotonaponskog sustava od planirane u višem sloju se rasporedio na način da je mikromreža manje energije preuzela iz nadređene elektroenergetske mreže, a u isto vrijeme se baterijski sustav pohrane energije punio umjesto praznio što je inicijalno bilo planirano u višem sloju sustava upravljanja energijom. U trećem karakterističnom razdoblju manjak energije nastao manjom proizvodnjom električne energije iz fotonaponskog sustava od planirane u višem sloju se pokrio korektivnim mjerama zbog kojih je mikromreža umjesto predaje električne energije u nadređenu elektroenergetsku mrežu počela preuzimati energiju, dok je baterijski sustav pohrane energije morao prazniti bateriju umjesto planiranog stanja mirovanja. Kako u promatranom razdoblju planiranja niti u jednom trenutku nije bilo planirane proizvodnje električne energije pomoću upravljivog generatora, zbog visokog troška rada, manjak odnosno višak električne energije unutar mikromreže se morao pokriti kroz ostala dva upravljiva elementa, mrežu i baterijski sustav pohrane energije. Udio manjka odnosno viška energije koji pojedini upravljivi element mikromreže pružaju odnosno preuzimaju ovisi o udjelima definiranim u izrazima 4-72 i 4-73 te o funkciji cilja optimizacijskog problema nižeg sloja sustava upravljanja energijom definirana u izrazu 4-74.

Implementacijom kosimulacijskog okruženja u nižem sloju sustava upravljanja energijom, u kojemu je model testne mikromreže realiziran u simulacijskom alatu za modeliranje

i analizu elektroenergetskih mreža, omogućena je integracija jednadžbi tokova snaga u optimizacijski problem što donosi mogućnost primjene dodatnih ograničenja. Za promatrani horizont planiranja prikazani su iznosi veličina koji su rezultat kratkoročnog planiranja optimizacijskim problemom nižeg sloja sustava upravljanja energijom mikromreže. Na slici 5.34 prikazani su naponi po pojedinim fazama na sabirnicama testne mikromreže čiji su nazivi definirani na jednofaznoj shemi mikromreže prikazane na slici 5.4. Osim planiranog pogona testne mikromreže, na napone na sabirnicama utječe i opterećenje ostatka testnog izvoda koje je nesimetrično i promjenjivo u vremenu. Na slici 5.34 vidljivo je kako su svi naponi unutar definiranih granica od ± 10 % nazivnog napona.

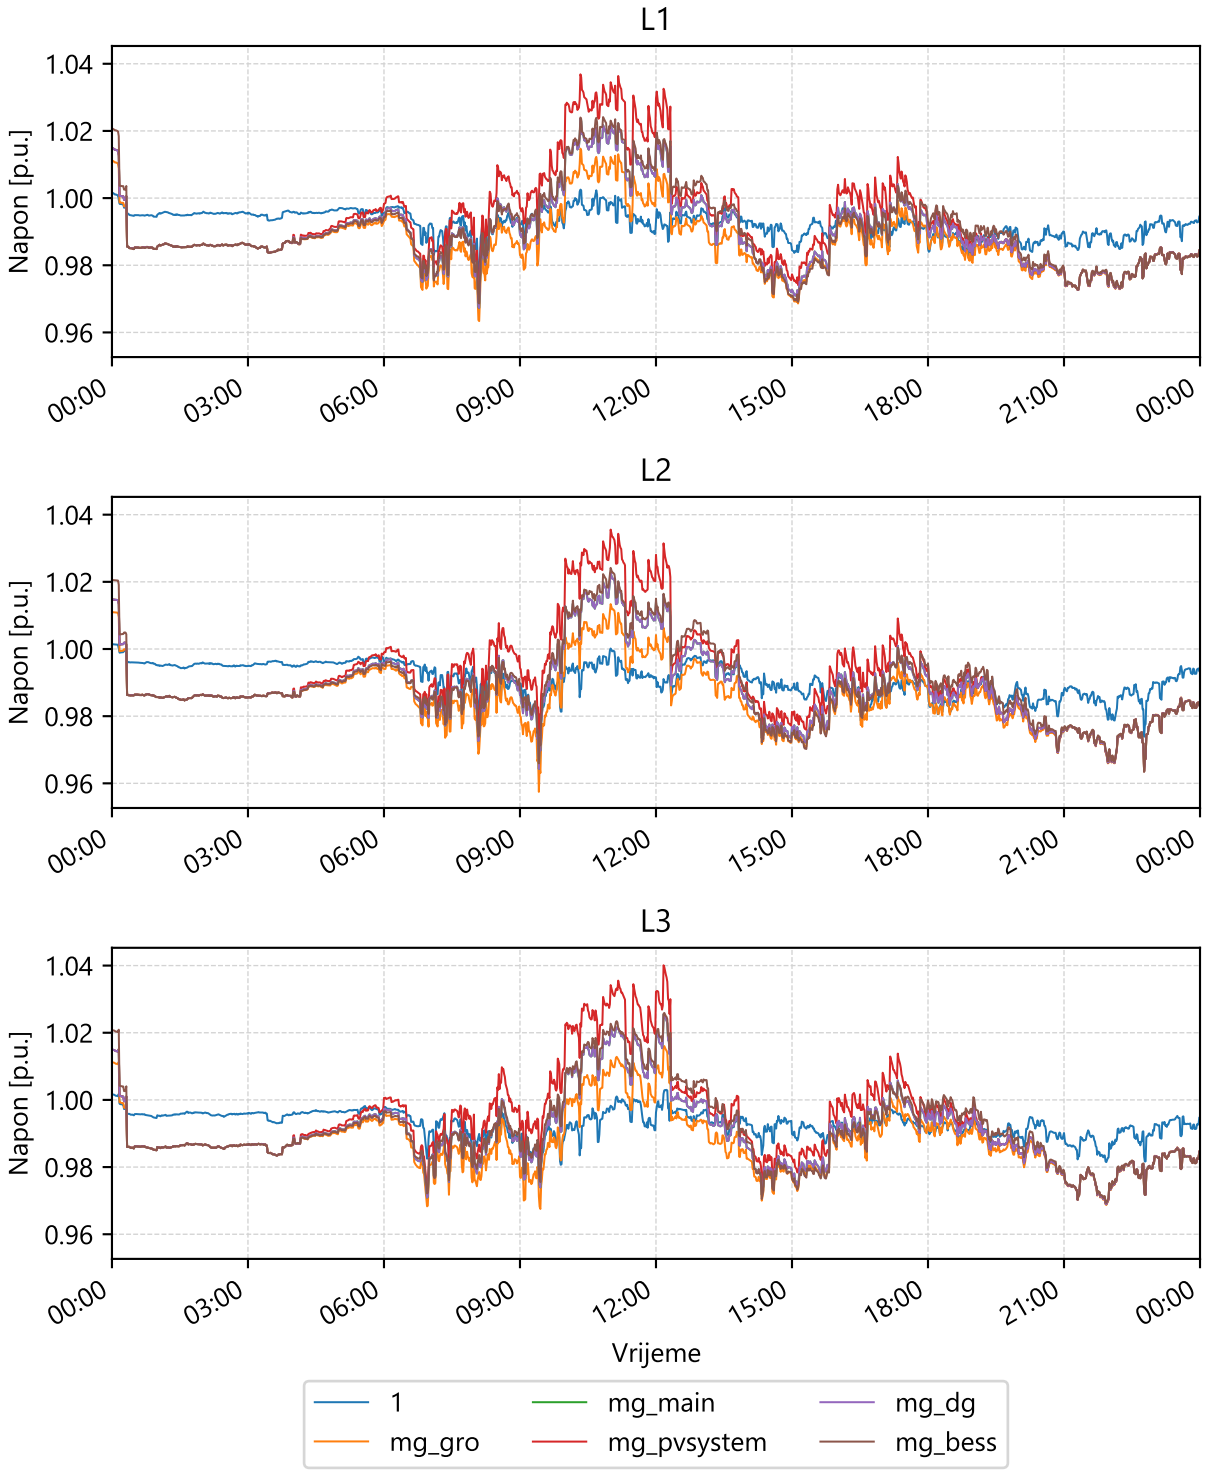

Slika 5.34: *Iznosi napona na sabirnicama testne mikromreže tijekom promatranog horizonta planiranja*

Opterećenja grana (kabela) u testnoj mikromreži tijekom promatranog horizonta planiranja prikazana su na slici 5.35. Nazivi kabela definirani su na jednofaznoj shemi testne mikromreže prikazanoj na slici 5.4. Slika 5.35 prikazuje da niti jedan kabel nije preopterećen tijekom kratkoročnog planiranja pogona testne mikromreže.

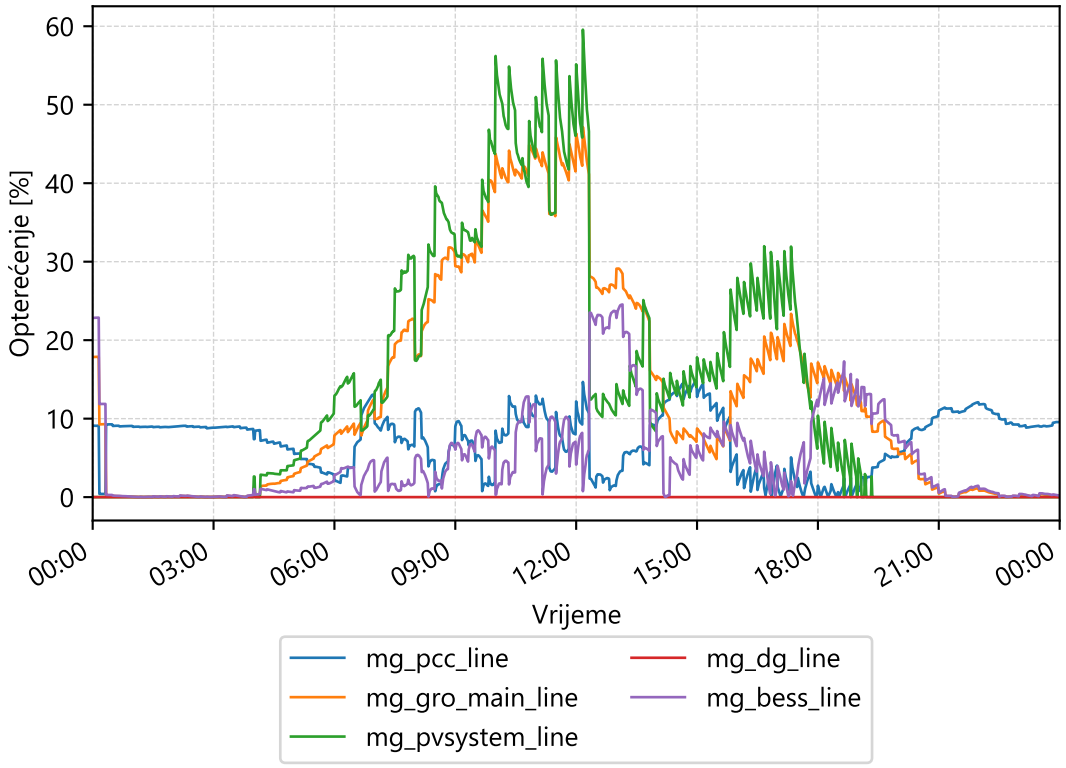

Slika 5.35: *Opterećenje grana (kabela) u testnoj mikromreži tijekom promatranog horizonta planiranja*

Snaga preuzimanja/predaje radne i jalove snage između testne mikromreže i nadređene elektroenergetske mreže tijekom promatranog horizonta planiranja prikazana je na slici P.11 u prilogu dok slika P.12 u prilogu prikazuje snagu razmjene radne i jalove snage između mikromreže i nadređene elektroenergetske mreže, snagu (radnu i jalovu) opterećenja ostatka niskonaponskog (NN) izvoda i snagu (radnu i jalovu) iz referentnog čvora testnog sustava (nadređena mreža) tijekom promatranog horizonta planiranja. Slika P.12 u prilogu prikazuje vrlo malu potrebu mikromreže za jalovom snagom jer potrošnja testne mikromreže ima jedinični faktor snage. Ova postavka je korištena jer regulacija jalove snage pomoću elemenata mikromreže nije u fokusu promatranja, niti je uvrštena u funkciju cilja optimizacijskog problema nižeg sloja sustava upravljanja energijom. Gubici radne i jalove snage unutar testne mikromreže prikazani su na slici P.13. Iako niski po iznosu, gubici radne snage utječu na kratkoročno planiranje pogona testne mikromreže jer se moraju pokriti iz jednog od upravljivih izvora mikromreže radi zadovoljenja bilance tokova radne snage.

U nastavku se promatra utjecaj optimizacijskog okvira na kratkoročno planiranje pogona mikromreže za tri podslučaja referentnog slučaja grafičkom usporedbom rezultata planiranja pogona upravljivih elemenata testne mikromreže. Kako u promatranom horizontu planiranja u nijednom trenutku nije planirano korištenje upravljivog generatora, analiziraju se samo profili razmjene električne energije između testne mikromreže i nadređene elektro-

energetske mreže te baterijskog sustava pohrane energije kao ostala dva upravljiva elementa testne mikromreže. Slika 5.36 prikazuje profil preuzimanja/predaje električne energije iz/u nadređenu elektroenergetsku mrežu tijekom promatranog horizonta planiranja za tri podslučaja koja vrednuju utjecaj optimizacijskog okvira na kratkoročno planiranje pogona testne mikromreže. Slika 5.36 prikazuje razlike u profilima razmjene električne energije između mikromreže i nadređene elektroenergetske mreže s obzirom na razinu optimizacijskog okvira definirana pomoću tri podslučaja. Referentni slučaj (podslučaj 3.1) predstavlja optimizacijski okvir koji nudi najbolju razinu adaptivnosti na buduće promjene uzrokovane promjenama u prognozama ulaznih parametara u optimizacijske probleme pojedinih slojeva sustava upravljanja energijom. Profil razmjene električne energije između testne mikromreže i nadređene elektroenergetske mreže za podslučaj 3.2 odstupa od referentnog slučaja (podslučaj 3.1) jer kod podslučaja 3.2 sustav upravljanja energijom ne koristi niži sloj, stoga nema ni dostupne prognoze ulaznih parametara korištene za optimizacijski problem nižeg sloja sustava upravljanja energijom. Profil razmjene električne energije u podslučaju 3.3 rezultat je optimizacijskog okvira koji nema nikakvo svojstvo adaptivnosti tijekom promatranog horizonta planiranja i ovisi o prognozama ulaznih parametara nastale netom prije prve iteracije optimizacije za promatrani horizont planiranja.

Slika 5.37 prikazuje profil punjenja i pražnjenja baterijskog sustava pohrane energije u promatranom horizontu planiranja za tri promatrana podslučaja. Kao i kod slučaja profila razmjene električne energije između testne mikromreže i nadređene elektroenergetske mreže, profil rada baterijskog sustava upravljanja energijom razlikuje se po promatranim podslučajevima. Slika 5.37 prikazuje kako snaga punjenja/pražnjenja i stanje napunjenosti baterijskog sustava pohrane energije za podslučajeve 3.2 i 3.3 uvelike odstupaju od profila za referentni slučaj (podslučaj 3.1). Razlike između profila za podslučajeve 3.2 i 3.3 nastale su zbog nedostupnosti točnijih prognoza ulaznih parametara u optimizacijski problem što uzrokuje lošiju razinu adaptivnosti na promjene dok podslučaj 3.3. osim razlika u prognozama nema ni ugrađeno svojstvo adaptivnosti (*online* optimizacija).

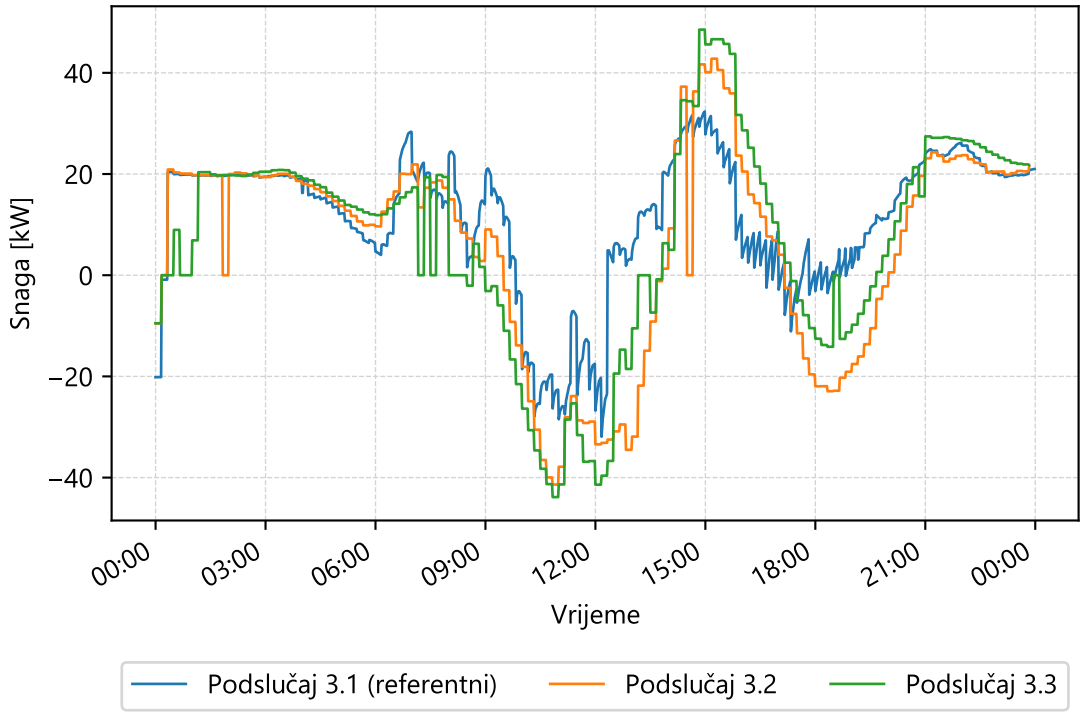

Slika 5.36: *Profil snage preuzimanja i predaje električne energije iz/u nadređenu elektroenergetsku mrežu u promatranom horizontu planiranja za sva tri podslučaja*

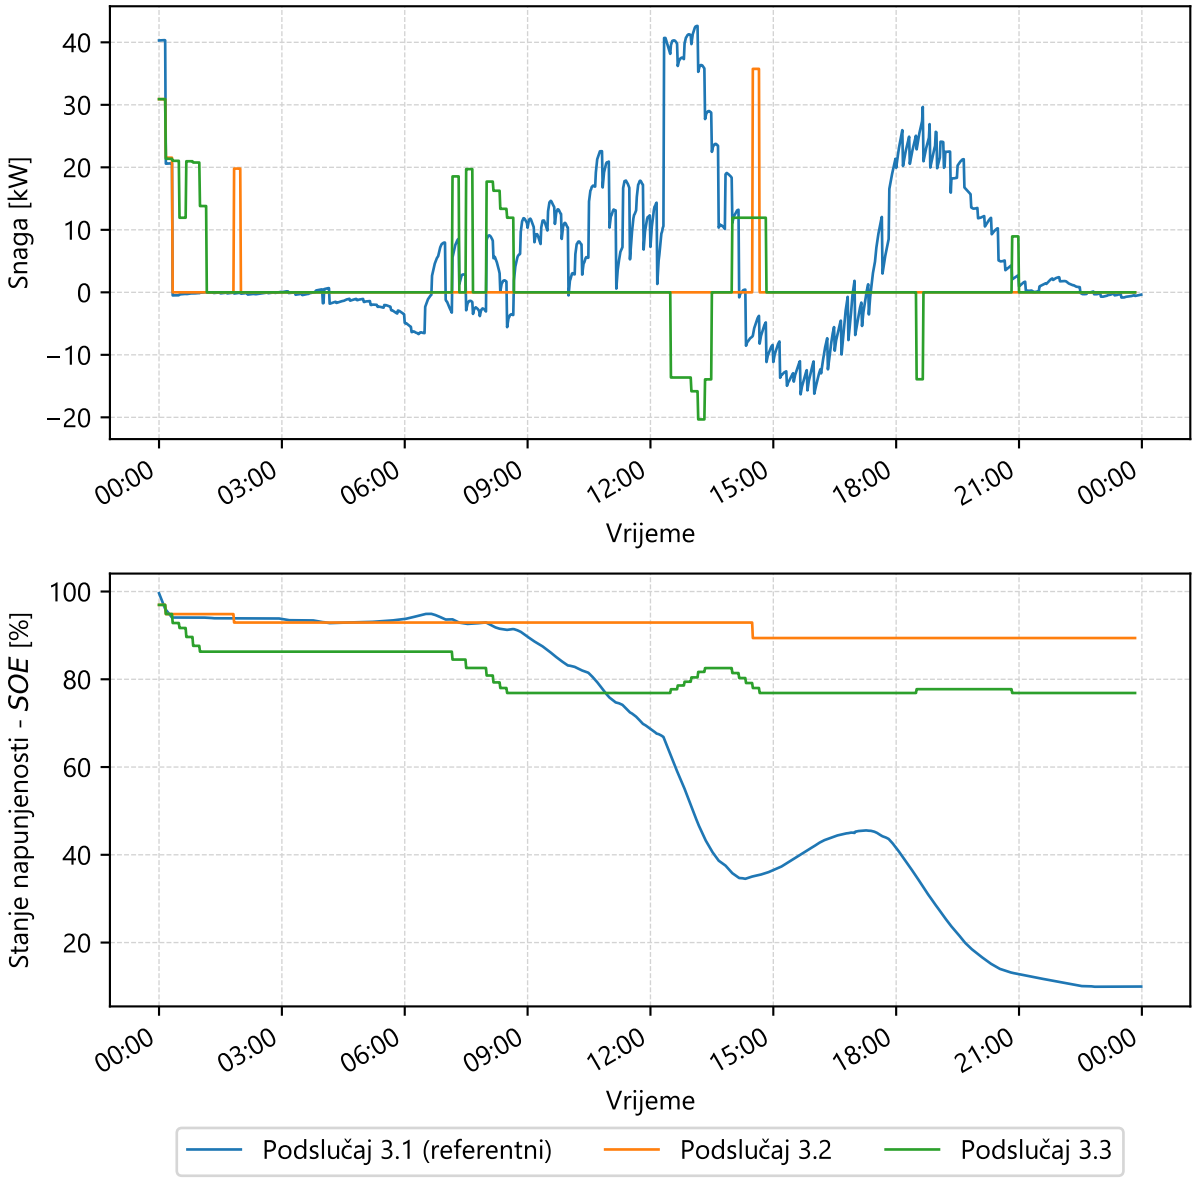

Slika 5.37: *Profil punjenja i pražnjenja baterijskog sustava pohrane energije u promatranom horizontu planiranja za sva tri podslučaja*

5.4.3. Analiza osjetljivosti funkcije cilja optimizacijskog problema višeg sloja sustava upravljanja energijom na postavke elemenata testne mikromreže

U ovom poglavlju je izvršena analiza osjetljivosti funkcije cilja optimizacijskog problema višeg sloja sustava upravljanja energijom za referentni slučaj s ciljem analize utjecaja postavki elemenata testne mikromreže na kratkoročni pogon. Analiza osjetljivosti izvršava se na osnovu ulaznih podataka predviđenih za horizont predviđanja (PH_1) odnosno za samo jedan vremenski korak (iteraciju optimizacije). Osim za vrijednosti funkcije cilja, analiza osjetljivosti provodi se i za neto vrijednost svih pogonskih prihoda/troškova i za neto vrijednost svih dodatnih (virtualnih) prihoda/troškova. Analiza osjetljivosti provodi se za dva karak-

teristična slučaja: smanjenje postavki elemenata mikromreže na 50% početne (referentne) vrijednosti i povećanje postavki elemenata mikromreže za 50% odnosno na iznos od 150% početne (referentne) vrijednosti. Referentna vrijednost funkcije cilja, neto vrijednost svih pogonskih prihoda/troškova i neto vrijednost svih dodatnih (virtualnih) prihoda/troškova preuzeti su iz rezultata za referentni slučaj (3. podslučaj u poglavlju 5.4.1), prikazan u tablici 5.15.

Kod elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu) mijenjaju se sljedeće postavke:

- Jedinični trošak preuzimanja električne energije od opskrbljivača;
- Jedinična vrijednost predane električne energije opskrbljivaču;
- Jedinični trošak za angažiranu snagu;
- Povijesna vrijednost angažirane snage.

Kod elementa baterijskog sustava pohrane energije mijenjaju se sljedeće postavke:

- Trošak zamjene baterijskog sustava pohrane energije;
- Nazivna izmjenična snaga dvosmjernog pretvarača energetske elektronike i energetski kapacitet baterije;
- Životni vijek baterije.

Kod elementa baterijskog sustava pohrane energije postavke koje se mijenjaju su:

- Nazivna izmjenična snaga izmjenjivača i snaga fotonaponskog polja (instalirana snaga).

Analiza osjetljivosti je izvršena na postavke upravljivog generatora i postavke statički upravljivog trošila, no rezultati nisu prikazani jer nisu imali utjecaj na vrijednost funkcije cilja budući da u promatranom horizontu planiranja nije planiran rad upravljivog generatora, niti je planirano upravljanje potrošnjom statički upravljivog trošila.

Kod promjene troška zamjene baterijskog sustava pohrane energije korištena je linearna promjena investicijskog troška komponenti snage (dvosmjerni pretvarač energetske elektronike) i investicijskog troška energetskih komponenti (energetski kapacitet baterije). Ista metodologija primijenjena je i kod promjene nazivne izmjenične snage dvosmjernog pretvarača energetske elektronike i energetskog kapaciteta baterije. Rezultat navedenog je nepromijenjeno trajanje korištenja baterijskog sustava pohrane energije. Kod fotonaponskog sustava također je korištena linearna promjena nazivne izmjenične snage izmjenjivača i snage fotonaponskog polja.

Analiza osjetljivosti promatra se s tri aspekta, utjecaj na vrijednost funkcije cilja, utjecaj na neto vrijednost svih pogonskih prihoda/troškova i utjecaj na neto vrijednost svih dodatnih

(virtualnih) prihoda/troškova testne mikromreže. Tablica 5.18 prikazuje rezultate analize osjetljivosti funkcije cilja optimizacijskog problema višeg sloja sustava upravljanja energijom na postavke elemenata testne mikromreže. Negativna vrijednost predstavlja gubitak odnosno trošak dok pozitivna vrijednost predstavlja profit odnosno prihod.

Tablica 5.18: *Analiza osjetljivosti vrijednosti funkcije cilja, neto pogonskih prihoda/troškova i neto dodatnih (virtualnih) prihoda/troškova na postavke elemenata testne mikromreže*

Element	**Postavka**	**Vrijednost funkcije cilja [kn]**			**Neto pogonski prihodi/-troškovi [kn]**			**Neto dodatni (virtualni) prihodi/-troškovi [kn]**		
		50 %	100 %	150 %	50 %	100 %	150 %	50 %	100 %	150 %
Mreža	Jedinični trošak preuzimanja električne energije [kn/kWh]	-168.06	-230.47	-279.64	-70.59	-158.53	-219.41	-97.47	-71.94	-60.23
	Jedinična vrijednost predane električne energije [kn/kWh]	-248.77	-230.47	-200.02	-165.07	-158.53	-128.24	-83.7	-71.94	-71.77
	Jedinični trošak za angažiranu snagu [kn/kW]	-232.36	-230.47	-232.13	-159.25	-158.53	-160.36	-73.11	-71.94	-71.77
	Povijesna vrijednost angažirane snage [kW]	-232.97	-230.47	-229.76	-149.84	-158.53	-158.68	-83.13	-71.94	-71.08
BESS*	Trošak zamjene baterijskog sustava pohrane energije [kn/kWh]	-148.83	-230.47	-306.36	-150.25	-158.53	-164.16	-1.42	-71.94	-142.2
	Nazivna izmjenična snaga dvosmjernog pretvarača energetske elektronike [kW] i energetski kapacitet baterije [kWh]	-206.58	-230.47	-253.18	-169.72	-158.53	-153.18	-36.86	-71.94	-100
	Životni vijek baterije [god]	-375.32	-230.47	-185.67	-127.98	-158.53	-155.92	-247.35	-71.94	-29.75
FN** sustav	Instalirana snaga fotonaponskog sustava [kW]	-902.06	-230.47	-36.74	-814.43	-158.53	33.83	-87.63	-71.94	-70.57

*BESS - baterijski sustav pohrane energije; **FN - fotonaponski

Rezultati analize osjetljivosti su prikazani i grafički gdje su radi lakše usporedivosti vrijednosti funkcije cilja, neto vrijednosti svih pogonskih prihoda/troškova i neto vrijednosti svih dodatnih (virtualnih) prihoda/troškova za promatrane slučajeve (50 % i 150 %) izraženi su u odnosu na referentne vrijednosti (100 %).

Slika 5.38 prikazuje analizu osjetljivosti vrijednosti funkcije cilja s obzirom na postavke elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu), postavke baterijskog sustava pohrane energije i postavke fotonaponskog sustava. Pozitivne vrijednosti predstavljaju povećanje vrijednosti funkcije cilja i obrnuto. Kako je vrijednost funkcije cilja u svim promatranim slučajevima negativna (gubitak), povećanje njene vrijednosti označuje manji ukupni gubitak dok smanjenje znači veći ukupni gubitak.

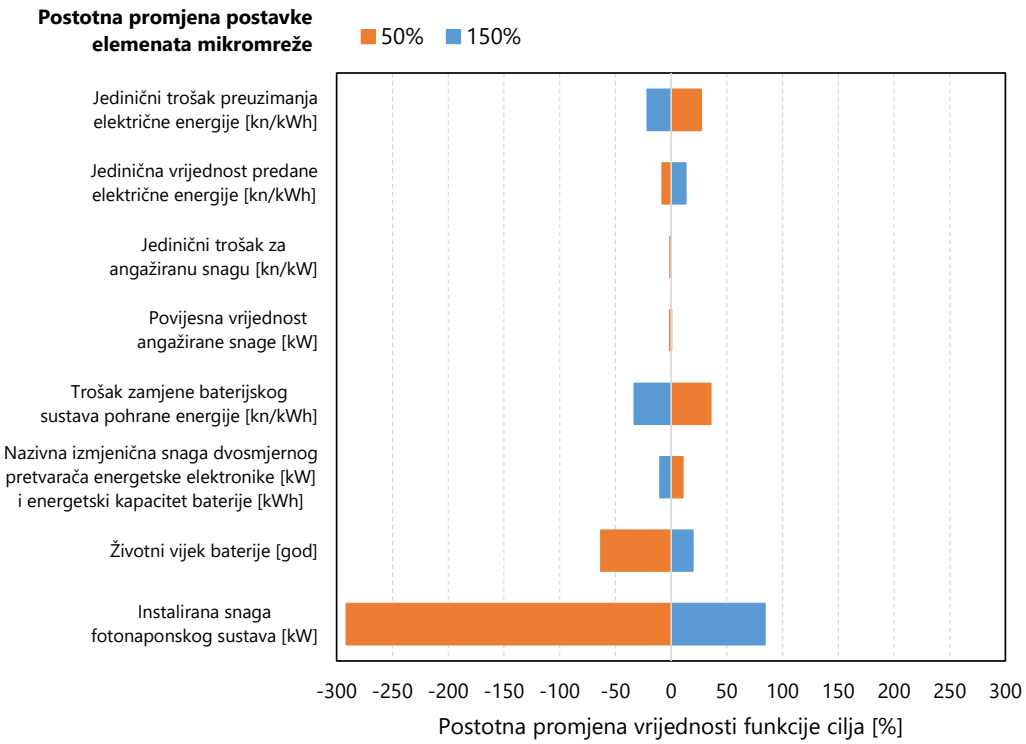

Slika 5.38: *Analiza osjetljivosti vrijednosti funkcije cilja na postavke elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu), postavke baterijskog sustava pohrane energije i postavke fotonaponskog sustava*

Slika 5.39 prikazuje analizu osjetljivosti neto vrijednosti svih pogonskih prihoda/troškova s obzirom na postavke elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu), postavke baterijskog sustava pohrane energije i postavke fotonaponskog sustava. Pozitivne vrijednosti predstavljaju smanjenje neto vrijednosti pogonskih prihoda/troškova i obratno.

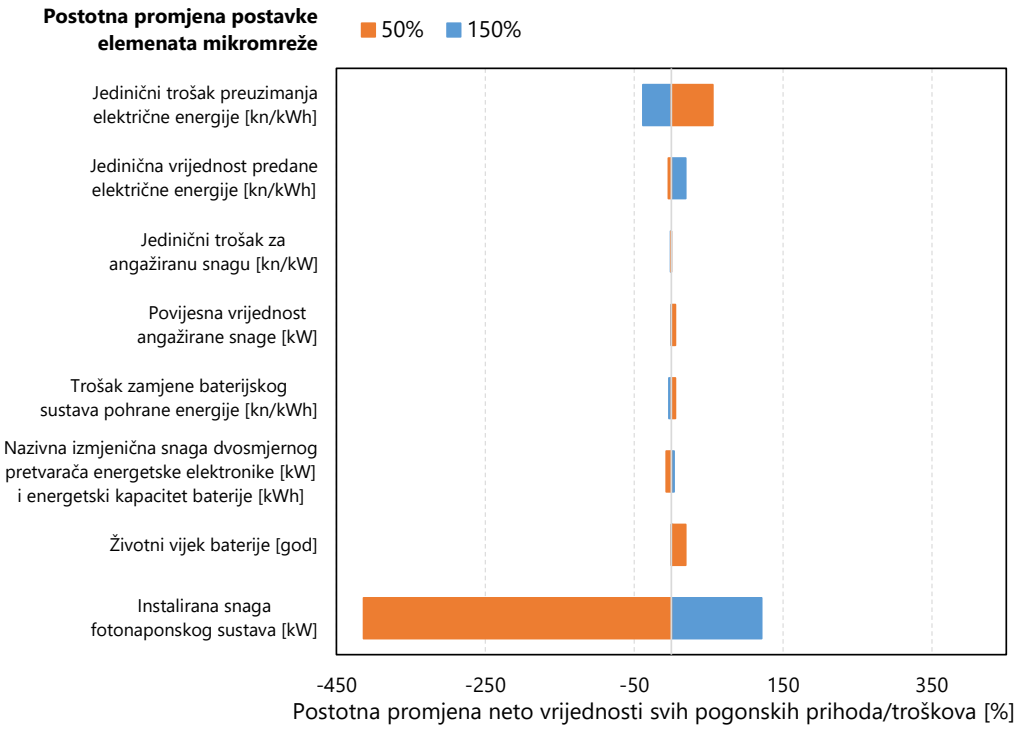

Slika 5.39: *Analiza osjetljivosti neto vrijednosti svih pogonskih prihoda/troškova na postavke elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu), postavke baterijskog sustava pohrane energije i postavke fotonaponskog sustava*

Slika 5.40 prikazuje analizu osjetljivosti neto vrijednosti svih dodatnih (virtualnih) prihoda/troškova s obzirom na postavke elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu), postavke baterijskog sustava pohrane energije i postavke fotonaponskog sustava. Pozitivne vrijednosti predstavljaju smanjenje neto vrijednosti svih dodatnih (virtualnih) prihoda/troškova i obratno.

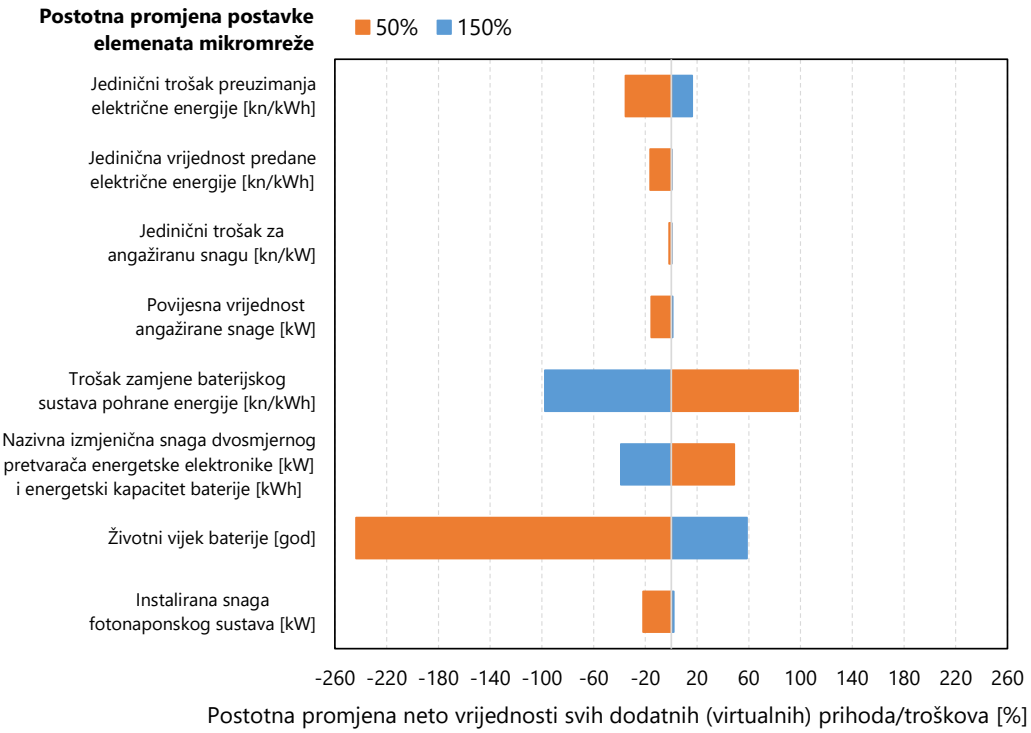

Slika 5.40: *Analiza osjetljivosti neto vrijednosti svih dodatnih (virtualnih) prihoda/troškova na postavke elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu), postavke baterijskog sustava pohrane energije i postavke fotonaponskog sustava*

Iz rezultata se zaključuje kako najveći utjecaj na vrijednost funkcije cilja te neto vrijednost svih pogonskih prihoda/troškova ima instalirana snaga fotonaponskog sustava. Smanjenje instalirane snage fotonaponskog sustava za 50 % rezultira većim ukupnim troškom preuzete električne energije dok povećanje instalirane snage za 50 % (slučaj 150 %) rezultira većim prihodom od predane električne energije, nego troškom za preuzetu električnu energiju, čime je mikromreža ostvarila dobitak u pogledu pogonskih prihoda/troškova.

Sljedeće postavke koje imaju velik utjecaj na vrijednost funkcije cilja su trošak zamjene (investicijski trošak) baterijskog sustava pohrane energije, životni vijek baterije i jedinični trošak preuzimanja električne energije. Troškovi vezani uz baterijski sustav pohrane energije imaju izravni utjecaj na neto vrijednost svih dodatnih (virtualnih) prihoda/troškova, a posljedično i na vrijednost funkcije cilja zbog povećanja/smanjenja troškova degradacije dok na pogonske troškove nema prevelik utjecaj.

Jedinični trošak za preuzimanje električne energije ima veći utjecaj od jedinične vrijednosti prilikom predaje električne energije opskrbljivaču jer mikromreža puno više preuzima energije nego što predaje u mrežu (negativna neto vrijednost svih pogonskih prihoda/troškova).

Jedinični trošak za angažiranu snagu i povijesna vrijednost angažirane snage imaju vrlo mali utjecaj na vrijednost funkcije cilja i na neto vrijednost svih pogonskih i dodatnih (vir-

tualnih) prihoda/troškova. Ovo je očekivano jer se oba troška nadovezuju na iznosom velik jedinični trošak za angažiranu snagu što uvelike utječe na kratkoročno planiranje pogona testne mikromreže.

Ako se zasebno promotre slike 5.38, 5.39 i 5.40 može se zaključiti kako postavke baterijskog sustava pohrane energije imaju najveći utjecaj na neto vrijednost svih dodatnih (virtualnih) prihoda/troškova dok je njihov utjecaj na pogonske troškove zanemariv.

6. Zaključak

Integracija promjenjive proizvodnje i potrošnje električne energije u mikromrežu donosi izazove u pogledu planiranja njihovog pogona u budućnosti. U posljednje vrijeme ova tema dobiva na važnosti u znanstvenoj literaturi kroz dizajniranje sustava upravljanja energijom čiji je osnovni zadatak optimalno planirati pogon mikromreža. Pogon mikromreža može se planirati s obzirom na različite postavljene ciljeve od kojih je najčešće korišteni ekonomskog karaktera. Naglasak u znanstvenoj literaturi u ovom području se stavlja na razvoj sustava upravljanja energijom s optimizacijskim okvirima koji donose adaptivnost na promjene nastale tijekom pogona, a koje mogu udaljiti pogon mikromreže od optimalnog.

Tijekom razvoja optimizacijskog modela sustava upravljanja energijom pojavljuju se dvije oprečne karakteristike, duljina horizonta planiranja i duljina vremenskog koraka optimizacije. Duljim horizontom planiranja postiže se bolja otpornost na promjene, no povećava se računalna složenost optimizacijskog modela i obrnuto. Duljim vremenskim korakom optimizacije postiže se smanjenje računalne složenosti modela, no narušava se njegova otpornost zbog nemogućnosti identificiranja promjena nastalih tijekom njegovog trajanja i obrnuto. Rješenje problema postiže se raščlanjivanjem optimizacijskog postupka na više međusobno povezanih optimizacijskih problema (slojeva) različitih svojstava i različite razine računalne složenosti kojima se postiže kompromisno rješenje za učinkovitije planiranje pogona. Sveobuhvatnom analizom literature, istraživanje u ovoj disertaciji usmjerilo se na tri izvorna znanstvena doprinosa: razvoj sustava upravljanja energijom mikromreže s unaprijeđenim optimizacijskim okvirom temeljenog na dva međusobno povezana optimizacijska problema (viši i niži sloj) čime se poboljšava otpornost na promjene, razvoj unaprijeđenog modela baterijskog sustava pohrane energije te vrednovanje razvijenog sustava upravljanja energijom planiranjem kratkoročnog pogona testne mikromreže.

Prvi izvorni znanstveni doprinos ostvaren je razvojem dvoslojnog adaptivnog sustava upravljanja energijom u kojemu je viši sloj realiziran kao mješovito cjelobrojni linearni optimizacijski problem s duljim horizontom planiranja i većim vremenskim korakom, a implementiran je u okviru strategije pomičnog horizonta s korektivnim djelovanjem i s ciljem maksimizacije dobiti mikromreže tijekom horizonta planiranja. Niži sloj je realiziran kao nelinearni optimizacijski problem u kosimulacijskom okruženju s kraćim horizontom planiranja

i kraćim vremenskim korakom u odnosu na viši sloj, koji uvažava električka ograničenja elektroenergetske mreže te ima tehnički cilj minimizacije odstupanja od planiranih vrijednosti višim slojem (minimizacija korektivnih mjera) u gotovo stvarnom vremenu. Sustav upravljanja energijom modelira trošak novoangažirane snage kojim se može postići smanjenje vršnog opterećenja mikromreže, omogućuje i umreženi i izolirani pogon mikromreže u odnosu na nadređenu elektroenergetsku mrežu, integrira upravljiva trošila i integrira upravljivi generator kao dodatni (rezervni) izvor električne energije. Ulazni podaci u optimizacijske probleme se predviđaju uz pomoć različitih metoda ovisno o sloju sustava upravljanja energijom i veličini koja se predviđa. Srednjoročne prognoze za viši sloj podrazumijevaju predviđanje meteoroloških parametara za distribuirane izvore na obnovljive izvore energije (fotonaponski sustav) pomoću modela numeričkog predviđanja vremena i predviđanje potrošnje električne energije pomoću umjetne neuronske mreže s dugom kratkoročnom memorijom. Kratkoročne prognoze meteoroloških parametara i potrošnje električne energije za niži sloj također se predviđaju pomoću umjetne neuronske mreže s dugom kratkoročnom memorijom.

Drugi izvorni znanstveni doprinos ostvaren je razvojem unaprijeđenog modela baterijskog sustava pohrane energije. Razvijeni model modelira dvosmjerni pretvarač energetske elektronike i njegovu učinkovitost ovisnu o opterećenju, koristi energetski model punjenja baterije u svrhu ograničavanja snage punjenja baterije, modelira trošak cikličkog i kalendarskog starenja baterije s ciljem produljenja životnog vijeka opreme i valorizira pohranjenu energiju u bateriji s ciljem regulacije stanja napunjenosti baterije tijekom planiranja pogona.

Treći izvorni znanstveni doprinos ostvaren je vrednovanjem razvijenog sustava upravljanja energijom kratkoročnim planiranjem pogona testne mikromreže. Vrednovanje razvijenog sustava je podijeljeno na tri dijela (analize). U prvom dijelu se analizirao utjecaj dodatnih (virtualnih) prihoda/troškova funkcije cilja optimizacijskog problema višeg sloja kojom je utvrđeno kako razina složenosti odnosno realnosti modela baterijskog sustava pohrane energije ima najveći utjecaj na kratkoročno planiranje pogona mikromreže. Razvijeni model omogućuje vođenje različitih strategija s obzirom na pogon baterijskog sustava pohrane energije, a i same mikromreže. Valorizacija pohranjene energije u baterijskom sustavu pohrane energije utječe na stanje napunjenosti tijekom promatranog horizonta planiranja dok izračun troška degradacije omogućuje produljenje životnog vijeka opreme, no uz povećanje pogonskih troškova mikromreže. Iako u promatranim podslučajevima nije bilo troškova za novoangažiranu snagu, ovaj modelirani aspekt utječe na kratkoročno planiranje pogona mikromreže kroz smanjenje vršnog opterećenja mikromreže odnosno snage preuzimanja električne energije iz nadređene elektroenergetske mreže. Vremenski odgodivo trošilo se koristilo u svim promatranim podslučajevima dok se upravljanje potrošnjom statički upravljivog trošila koristilo samo u slučaju izoliranog pogona mikromreže u odnosu na nadređenu elektro-

energetsku mrežu. Ovime se postigao postavljeni cilj upotrebe rasterećenja samo u slučaju nužde budući da se u normalnim pogonskim prilikama upravljanje potrošnjom ovim tipom trošila ne želi koristiti. Analizom pokazatelja vlastite potrošnje i pokazatelja samodostatnosti opskrbe, može se zaključiti da najveći utjecaj na njihov iznos ima lokalna proizvodnja električne energije iz fotonaponskog sustava koji predstavlja najveći izvor električne energije u mikromreži.

U drugom dijelu analize se razmatrao utjecaj optimizacijskog okvira na kratkoročno planiranje pogona testne mikromreže. Uspoređujući optimizacijske okvire zaključuje se kako razvijeni dvoslojni adaptivni sustav upravljanja energijom nudi najbolju razinu adaptivnosti na buduće promjene uzrokovane prognozama ulaznih parametara optimizacijskih problema. Kratkoročno planiranje pogona mikromreže najviše ovisi o razini točnosti prognoza ulaznih parametara u optimizacijske probleme. Manjak ili višak električne energije iz određenog elementa mikromreže koji je nastao zbog netočnih prognoza u višem sloju pokrio se kroz neki od upravljivih elemenata mikromreže čiji se pogon planira pomoću optimizacijskog problema nižeg sloja sustava upravljanja energijom.

U trećem dijelu analize izvršena je analiza osjetljivosti funkcije cilja optimizacijskog problema višeg sloja sustava upravljanja energijom na postavke elemenata mikromreže. U analizi se promatrao utjecaj na vrijednost funkcije cilja, neto vrijednost svih pogonskih prihoda/troškova te neto vrijednost svih dodatnih (virtualnih) prihoda/troškova mikromreže. Najveći utjecaj na vrijednost funkcije cilja i neto vrijednost pogonskih prihoda/troškova ima instalirana snaga fotonaponskog sustava dok najveći utjecaj na dodatne (virtualne) prihode/troškove ima baterijski sustav pohrane energije.

Razvijeni dvoslojni sustav upravljanja energijom prema mišljenju autora ove disertacije omogućuje daljnji razvoj u više smjerova. Jedan od smjerova je nadogradnja razvijenog sustava upravljanja energijom koji bi omogućio regulaciju tokova jalove snage (osim trenutno radne snage) u svrhu regulacije napona unutar i izvan mikromreže kroz uvrštavanje novih varijabli i ograničenja u optimizacijski problem nižeg sloja sustava upravljanja energijom, a čija se opravdanost i obveze definiraju mrežnim pravilima distribucijskog sustava. Nadalje, optimizacijski okvir i funkcije cilja sustava upravljanja energijom mogu se prilagoditi tako da mikromreža sudjeluje na dan-unaprijed i unutardnevnom tržištu električne energije. Mogući smjer daljnjeg istraživanja predstavlja i nadogradnja funkcije cilja članom koji bi valorizirao dodatni prihod sudjelovanjem u portfelju agregatora distribuiranih pružatelja usluga fleksibilnosti na tržištu električne energije. Naposlijetku, model baterijskog sustava pohrane energije može se dodatno unaprijediti metodologijom koja bi pratila stanje zdravlja opreme, a što bi operatoru mikromreže omogućilo kontinuirano praćenje preostalog životnog vijeka i donošenje strateških odluka u vođenju pogona mikromreže za dulje vremensko razdoblje.

Literatura

[1] REN21, "Renewables 2021: Global status report," REN21 Secretariat, Tech. Rep., 2021.

[2] N. Hatziargyriou, Ed., *Microgrids: Architectures and Control*. John Wiley & Sons, 2014.

[3] D. T. Ton and M. A. Smith, "The U.S. Department of Energy's Microgrid Initiative," *The Electricity Journal*, vol. 25, no. 8, pp. 84–94, 2012.

[4] T. L. Vandoorn, J. C. Vasquez, J. D. Kooning, J. M. Guerrero, and L. Vandevelde, "Microgrids: Hierarchical control and an overview of the control and reserve management strategies," *IEEE Industrial Electronics Magazine*, vol. 7, no. 4, pp. 42–55, 2013.

[5] Institute of Electrical and Electronics Engineers (IEEE), *2030.7-2017 - IEEE Standard for the Specification of Microgrid Controllers*, Institute of Electrical and Electronics Engineers (IEEE) Std., 2018.

[6] M. Azaza and F. Wallin, "Multi objective particle swarm optimization of hybrid microgrid system: A case study in sweden," *Energy*, vol. 123, pp. 108–118, 2017.

[7] A. A. Bashir and M. Lehtonen, "Day-ahead rolling window optimization of islanded microgrid with uncertainty," in *2018 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)*. IEEE, 2018.

[8] S. F. Contreras, C. A. Cortes, and J. M. Myrzik, "Multi-objective probabilistic power resources planning for microgrids with ancillary services capacity," in *2018 Power Systems Computation Conference (PSCC)*. IEEE, 2018.

[9] S. F. CONTRERAS, C. A. CORTES, and J. M. A. MYRZIK, "Optimal microgrid planning for enhancing ancillary service provision," *Journal of Modern Power Systems and Clean Energy*, vol. 7, no. 4, pp. 862–875, 2019.

[10] M. F. Zia, E. Elbouchikhi, and M. Benbouzid, "Microgrids energy management systems: A critical review on methods, solutions, and prospects," *Applied Energy*, vol. 222, pp. 1033–1055, 2018.

[11] M. Zachar and P. Daoutidis, "Energy management and load shaping for commercial microgrids coupled with flexible building environment control," *Journal of Energy Storage*, vol. 16, pp. 61–75, 2018.

[12] L. K. Panwar, S. R. Konda, A. Verma, B. K. Panigrahi, and R. Kumar, "Operation window constrained strategic energy management of microgrid with electric vehicle and distributed resources," *IET Generation, Transmission & Distribution*, vol. 11, no. 3, pp. 615–626, 2017.

[13] E. L. Ratnam and S. R. Weller, "Receding horizon optimization-based approaches to managing supply voltages and power flows in a distribution grid with battery storage co-located with solar PV," *Applied Energy*, vol. 210, pp. 1017–1026, 2018.

[14] J. Silvente, G. M. Kopanos, E. N. Pistikopoulos, and A. Espuña, "A rolling horizon optimization framework for the simultaneous energy supply and demand planning in microgrids," *Applied Energy*, vol. 155, pp. 485–501, 2015.

[15] M. Mohammadjafari, R. Ebrahimi, and V. P. Darabad, "Optimal energy management of a microgrid incorporating a novel efficient demand response and battery storage system," *Journal of Electrical Engineering & Technology*, vol. 15, no. 2, pp. 571–590, 2020.

[16] S. Leonori, M. Paschero, F. M. F. Mascioli, and A. Rizzi, "Optimization strategies for microgrid energy management systems by genetic algorithms," *Applied Soft Computing*, vol. 86, p. 105903, 2020.

[17] S. Leonori, E. D. Santis, A. Rizzi, and F. F. Mascioli, "Optimization of a microgrid energy management system based on a fuzzy logic controller," in *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*. IEEE, 2016.

[18] G. M. Kopanos and E. N. Pistikopoulos, "Reactive scheduling by a multiparametric programming rolling horizon framework: A case of a network of combined heat and power units," *Industrial & Engineering Chemistry Research*, vol. 53, no. 11, pp. 4366–4386, 2014.

[19] S. Choi and S.-W. Min, "Optimal scheduling and operation of the ESS for prosumer market environment in grid-connected industrial complex," in *2017 IEEE Industry Applications Society Annual Meeting*. IEEE, 2017.

[20] S. Choi and S.-W. Min, "Optimal scheduling and operation of the ESS for prosumer market environment in grid-connected industrial complex," *IEEE Transactions on Industry Applications*, vol. 54, no. 3, pp. 1949–1957, 2018.

[21] I. Ciornei, M. Albu, M. Sanduleac, E. Rodriguez-Diaz, J. Guerrero, and J. C. Vasquez, "Real-time optimal scheduling for prosumers resilient to regulatory changes," in *2018 IEEE International Energy Conference (ENERGYCON)*. IEEE, 2018.

[22] F. Delfino, G. Ferro, M. Robba, and M. Rossi, "An energy management platform for the optimal control of active and reactive powers in sustainable microgrids," *IEEE Transactions on Industry Applications*, vol. 55, no. 6, pp. 7146–7156, 2019.

[23] M. Elkazaz, M. Sumner, and D. Thomas, "Real-time energy management for a small scale PV-battery microgrid: Modeling, design, and experimental verification," *Energies*, vol. 12, no. 14, p. 2712, 2019.

[24] M. Elkazaz, M. Sumner, and D. Thomas, "Energy management system for hybrid PV-wind-battery microgrid using convex programming, model predictive and rolling horizon predictive control with experimental validation," *International Journal of Electrical Power & Energy Systems*, vol. 115, p. 105483, 2020.

[25] M. Et-Taoussi, H. Ouadi, and H. E. Chakir, "Hybrid optimal management of active and reactive power flow in a smart microgrid with photovoltaic generation," *Microsystem Technologies*, vol. 25, no. 11, pp. 4077–4090, 2019.

[26] A. Gabash and P. Li, "Active-reactive optimal power flow in distribution networks with embedded generation and battery storage," *IEEE Transactions on Power Systems*, vol. 27, no. 4, pp. 2026–2035, 2012.

[27] M. A. Hossain, H. R. Pota, S. Squartini, and A. F. Abdou, "Modified PSO algorithm for real-time energy management in grid-connected microgrids," *Renewable Energy*, vol. 136, pp. 746–757, 2019.

[28] H. Karimi and S. Jadid, "Optimal energy management for multi-microgrid considering demand response programs: A stochastic multi-objective framework," *Energy*, vol. 195, p. 116992, 2020.

[29] Z. LUO, W. GU, Z. WU, Z. WANG, and Y. TANG, "A robust optimization method for energy management of CCHP microgrid," *Journal of Modern Power Systems and Clean Energy*, vol. 6, no. 1, pp. 132–144, 2017.

[30] T. G. Paul, S. J. Hossain, S. Ghosh, P. Mandal, and S. Kamalasadan, "A quadratic programming based optimal power and battery dispatch for grid-connected microgrid," *IEEE Transactions on Industry Applications*, vol. 54, no. 2, pp. 1793–1805, 2018.

[31] Y. Riffonneau, S. Bacha, F. Barruel, and S. Ploix, "Optimal power flow management for grid connected PV systems with batteries," *IEEE Transactions on Sustainable Energy*, vol. 2, no. 3, pp. 309–320, 2011.

[32] A. Parisio, E. Rikos, G. Tzamalis, and L. Glielmo, "Use of model predictive control for experimental microgrid optimization," *Applied Energy*, vol. 115, pp. 37–46, 2014.

[33] H. Zou, Y. Wang, S. Mao, F. Zhang, and X. Chen, "Online energy management in microgids considering reactive power," *IEEE Internet of Things Journal*, vol. 6, no. 2, pp. 2895–2906, 2019.

[34] M. Vukasovic and B. Vukasovic, "Modeling optimal deployment of smart home devices and battery system using MILP," in *2017 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)*. IEEE, 2017.

[35] S. Bahrami and V. W. S. Wong, "Security-constrained unit commitment for AC-DC grids with generation and load uncertainty," *IEEE Transactions on Power Systems*, vol. 33, no. 3, pp. 2717–2732, 2018.

[36] S. O. Ottesen and A. Tomasgard, "A stochastic model for scheduling energy flexibility in buildings," *Energy*, vol. 88, pp. 364–376, 2015.

[37] E. Amicarelli, T. Q. Tran, and S. Bacha, "Optimization algorithm for microgrids day-ahead scheduling and aggregator proposal," in *2017 IEEE International Conference on Environment and Electrical Engineering and 2017 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*. IEEE, 2017.

[38] A. L. Bella, M. Farina, C. Sandroni, and R. Scattolini, "Microgrids aggregation management providing ancillary services," in *2018 European Control Conference (ECC)*. IEEE, 2018.

[39] A. Majzoobi and A. Khodaei, "Application of microgrids in providing ancillary services to the utility grid," *Energy*, vol. 123, pp. 555–563, 2017.

[40] J. Shen, C. Jiang, Y. Liu, and X. Wang, "A microgrid energy management system and risk management under an electricity market environment," *IEEE Access*, vol. 4, pp. 2349–2356, 2016.

[41] J. Wang, H. Zhong, W. Tang, R. Rajagopal, Q. Xia, C. Kang, and Y. Wang, "Optimal bidding strategy for microgrids in joint energy and ancillary service markets considering flexible ramping products," *Applied Energy*, vol. 205, pp. 294–303, 2017.

[42] W. Pei, Y. Du, H. Xiao, Z. Shen, W. Deng, and Y. Yang, "Optimal operation of microgrid with photovoltaics and gas turbines in demand response," in *2014 International Conference on Power System Technology*. IEEE, 2014.

[43] J. Shen, C. Jiang, Y. Liu, and J. Qian, "A microgrid energy management system with demand response for providing grid peak shaving," *Electric Power Components and Systems*, vol. 44, no. 8, pp. 843–852, 2016.

[44] R. Aboli, M. Ramezani, and H. Falaghi, "Joint optimization of day-ahead and uncertain near real-time operation of microgrids," *International Journal of Electrical Power & Energy Systems*, vol. 107, pp. 34–46, 2019.

[45] A. Ravichandran, S. Sirouspour, P. Malysz, and A. Emadi, "A chance-constraints-based control strategy for microgrids with energy storage and integrated electric vehicles," *IEEE Transactions on Smart Grid*, vol. 9, no. 1, pp. 346–359, 2018.

[46] C. Ju, P. Wang, L. Goel, and Y. Xu, "A two-layer energy management system for microgrids with hybrid energy storage considering degradation costs," *IEEE Transactions on Smart Grid*, vol. 9, no. 6, pp. 6047–6057, 2018.

[47] Z. Zhang, J. Wang, T. Ding, and X. Wang, "A two-layer model for microgrid real-time dispatch based on energy storage system charging/discharging hidden costs," *IEEE Transactions on Sustainable Energy*, vol. 8, no. 1, pp. 33–42, 2017.

[48] N. Holjevac, T. Capuder, N. Zhang, I. Kuzle, and C. Kang, "Corrective receding horizon scheduling of flexible distributed multi-energy microgrids," *Applied Energy*, vol. 207, pp. 176–194, 2017.

[49] D. M. López-Santiago and E. F. Caicedo, "Optimal management of electric power in microgrids under a strategic multi-objective decision-making approach and operational proportional adjustment," *IET Generation, Transmission & Distribution*, vol. 13, no. 19, pp. 4473–4481, 2019.

[50] J. S. Giraldo, J. A. Castrillon, J. C. Lopez, M. J. Rider, and C. A. Castro, "Microgrids energy management using robust convex programming," *IEEE Transactions on Smart Grid*, vol. 10, no. 4, pp. 4520–4530, 2019.

[51] M. Manbachi and M. Ordonez, "AMI-based energy management for islanded AC/DC microgrids utilizing energy conservation and optimization," *IEEE Transactions on Smart Grid*, vol. 10, no. 1, pp. 293–304, 2019.

[52] F. Yang, X. Feng, and Z. Li, "Advanced microgrid energy management system for future sustainable and resilient power grid," *IEEE Transactions on Industry Applications*, vol. 55, no. 6, pp. 7251–7260, 2019.

[53] A. Silani and M. J. Yazdanpanah, "Distributed optimal microgrid energy management with considering stochastic load," *IEEE Transactions on Sustainable Energy*, vol. 10, no. 2, pp. 729–737, 2019.

[54] J. L. Martinez-Ramos, A. Marano-Marcolini, F. P. Garcia-Lopez, F. Almagro-Yravedra, A. Onen, Y. Yoldas, M. Khiat, L. Ghomri, and N. Fragale, "Provision of ancillary services by a smart microgrid: An OPF approach," in *2018 International Conference on Smart Energy Systems and Technologies (SEST)*. IEEE, 2018.

[55] Q. Jiang, M. Xue, and G. Geng, "Energy management of microgrid in grid-connected and stand-alone modes," *IEEE Transactions on Power Systems*, vol. 28, no. 3, pp. 3380–3389, 2013.

[56] M. Sedighizadeh, M. Esmaili, A. Jamshidi, and M.-H. Ghaderi, "Stochastic multi-objective economic-environmental energy and reserve scheduling of microgrids considering battery energy storage system," *International Journal of Electrical Power & Energy Systems*, vol. 106, pp. 1–16, 2019.

[57] A. S. Farsangi, S. Hadayeghparast, M. Mehdinejad, and H. Shayanfar, "A novel stochastic energy management of a microgrid with various types of distributed energy resources in presence of demand response programs," *Energy*, vol. 160, pp. 257–274, 2018.

[58] M. H. Gomes and J. T. Saraiva, "Allocation of reactive power support, active loss balancing and demand interruption ancillary services in MicroGrids," *Electric Power Systems Research*, vol. 80, no. 10, pp. 1267–1276, 2010.

[59] S. Talari, M. Yazdaninejad, and M.-R. Haghifam, "Stochastic-based scheduling of the microgrid operation including wind turbines, photovoltaic cells, energy storages and

responsive loads," *IET Generation, Transmission & Distribution*, vol. 9, no. 12, pp. 1498–1509, 2015.

[60] C. Deckmyn, J. V. de Vyver, T. L. Vandoorn, B. Meersman, J. Desmet, and L. Vandevelde, "Day-ahead unit commitment model for microgrids," *IET Generation, Transmission & Distribution*, vol. 11, no. 1, pp. 1–9, 2017.

[61] M. A. Ramli, H. Bouchekara, and A. S. Alghamdi, "Efficient energy management in a microgrid with intermittent renewable energy and storage sources," *Sustainability*, vol. 11, no. 14, p. 3839, 2019.

[62] M. Jin, W. Feng, C. Marnay, and C. Spanos, "Microgrid to enable optimal distributed energy retail and end-user demand response," *Applied Energy*, vol. 210, pp. 1321–1335, 2018.

[63] H. Wang, N. Good, E. A. M. Cesena, and P. Mancarella, "Co-optimization of a multi-energy microgrid considering multiple services," in *2018 Power Systems Computation Conference (PSCC)*. IEEE, 2018.

[64] A. C. Luna, L. Meng, N. L. Diaz, M. Graells, J. C. Vasquez, and J. M. Guerrero, "Online energy management systems for microgrids: Experimental validation and assessment framework," *IEEE Transactions on Power Electronics*, vol. 33, no. 3, pp. 2201–2215, 2018.

[65] F. Díaz-González, A. Sumper, and O. Gomis-Bellmunt, *Energy Storage in Power Systems*. John Wiley & Sons, 2016.

[66] U.S. Department of Energy, "Energy Storage Grand Challenge: Energy StorageMarket Report," U.S. Department of Energy, Tech. Rep., 2020.

[67] C. K. Nayak, K. Kasturi, and M. R. Nayak, "Economical management of microgrid for optimal participation in electricity market," *Journal of Energy Storage*, vol. 21, pp. 657–664, 2019.

[68] S. Sukumar, H. Mokhlis, S. Mekhilef, K. Naidu, and M. Karimi, "Mix-mode energy management strategy and battery sizing for economic operation of grid-tied microgrid," *Energy*, vol. 118, pp. 1322–1333, 2017.

[69] A. C. Luna, N. L. Diaz, M. Graells, J. C. Vasquez, and J. M. Guerrero, "Mixed-integer-linear-programming-based energy management system for hybrid PV-wind-battery microgrids: Modeling, design, and experimental verification," *IEEE Transactions on Power Electronics*, vol. 32, no. 4, pp. 2769–2783, 2017.

[70] B. Xu, J. Zhao, T. Zheng, E. Litvinov, and D. S. Kirschen, "Factoring the cycle aging cost of batteries participating in electricity markets," *IEEE Transactions on Power Systems*, vol. 33, no. 2, pp. 2248–2259, 2018.

[71] M. Kassem, J. Bernard, R. Revel, S. Pélissier, F. Duclaud, and C. Delacourt, "Calendar aging of a graphite/LiFePO4 cell," *Journal of Power Sources*, vol. 208, pp. 296–305, 2012.

[72] J. Vetter, P. Novák, M. Wagner, C. Veit, K.-C. Möller, J. Besenhard, M. Winter, M. Wohlfahrt-Mehrens, C. Vogler, and A. Hammouche, "Ageing mechanisms in lithium-ion batteries," *Journal of Power Sources*, vol. 147, no. 1-2, pp. 269–281, 2005.

[73] S. Mohagheghi, J. Stoupis, Z. Wang, Z. Li, and H. Kazemzadeh, "Demand response architecture: Integration into the distribution management system," in *2010 First IEEE International Conference on Smart Grid Communications*. IEEE, 2010.

[74] M. Barukčić, "Optimiranje dinamičkog upravljanja kondenzatorskim baterijama u razdjelnim mrežama hibridnom metodom," Ph.D. dissertation, Elektrotehnički fakultet Osijek, 2012.

[75] S. Fallah, M. Ganjkhani, S. Shamshirband, and K. wing Chau, "Computational intelligence on short-term load forecasting: A methodological overview," *Energies*, vol. 12, no. 3, p. 393, 2019.

[76] A. Ahmed and M. Khalid, "A review on the selected applications of forecasting models in renewable power systems," *Renewable and Sustainable Energy Reviews*, vol. 100, pp. 9–21, 2019.

[77] M. Beus, F. Banis, H. Pandžić, and N. K. Poulsen, "Three-level hierarchical microgrid control—model development and laboratory implementation," *Electric Power Systems Research*, vol. 189, p. 106758, 2020.

[78] L. Söder and M. Amelin, *Efficient Operation and Planning of Power Systems*. Royal Institute of Technology Electric Power Systems, 2011.

[79] J. Nocedal and S. J. Wright, Eds., *Numerical Optimization*. Springer-Verlag, 1999.

[80] S. Bradley, C. Arnoldo, and T. L. Magnati, *Applied mathematical programming*. Reading, Mass: Addison-Wesley Pub. Co, 1977.

[81] F. S. Hillier and G. J. Lieberman, *Introduction to operations research*. Boston: McGraw-Hill, 2001.

[82] W. E. Hart, C. D. Laird, J.-P. Watson, D. L. Woodruff, and G. A. Hackebeil, *Pyomo - Optimization Modeling in Python*. Springer-Verlag GmbH, 2017.

[83] W. E. Hart, J.-P. Watson, and D. L. Woodruff, "Pyomo: modeling and solving mathematical programs in python," *Mathematical Programming Computation*, vol. 3, no. 3, pp. 219–260, 2011.

[84] Gurobi Optimization, LLC, "Gurobi Optimizer Reference Manual," https://www.gurobi.com/wp-content/plugins/hd_documentations/documentation/9.0/refman.pdf, pristup: 10. kolovoza 2021.

[85] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of ICNN'95 - International Conference on Neural Networks*. IEEE, 1995.

[86] E.-G. Talbi, *Metaheuristics*. John Wiley & Sons, 2009.

[87] F. Biscani and D. Izzo, "A parallel global multiobjective framework for optimization: pagmo," *Journal of Open Source Software*, vol. 5, no. 53, p. 2338, 2020.

[88] D. Izzo and F. Biscani, "PyGMO algorithms," https://esa.github.io/pygmo/documentation/algorithms.html, pristup: 10. kolovoza 2021.

[89] Electric Power Research Institute, "Simulation tool - OpenDSS," https://smartgrid.epri.com/SimulationTool.aspx, pristup: 11. kolovoza 2021.

[90] Electric Power Research Institute, *Reference Guide The Open Distribution System Simulation (OpenDSS)*, 2020.

[91] M.-H. Lin, J. G. Carlsson, D. Ge, J. Shi, and J.-F. Tsai, "A review of piecewise linearization methods," *Mathematical Problems in Engineering*, vol. 2013, pp. 1–8, 2013.

[92] H. Pandžić and V. Bobanac, "An accurate charging model of battery energy storage," *IEEE Transactions on Power Systems*, vol. 34, no. 2, pp. 1416–1426, 2019.

[93] S. Jenu, S. Tuurala, A. Manninen, M. Myllysilta, I. Deviatkin, K. Koponen, and A. Hentunen, "Smart system of renewable energy storage based on INtegrated EVs and bAtteries to empower mobile, Distributed and centralised Energy storage in the distribution grid - INVADE D6.4 Advanced state of health diagnostics tool," Horizon 2020 project deliverable, 2018.

[94] A. Hentunen, J. Forsström, and V. Mukherjee, "Smart system of renewable energy storage based on INtegrated EVs and bAtteries to empower mobile, Distributed and centralised Energy storage in the distribution grid - INVADE D6.5 Advanced battery techno-economics tool," Horizon 2020 project deliverable, 2018.

[95] W. Cole and A. Frazier, "Cost projections for utility-scale battery storage: 2020 update," National Renewable Energy Laboratory, Tech. Rep., 2020.

[96] J. Wang, J. Purewal, P. Liu, J. Hicks-Garner, S. Soukazian, E. Sherman, A. Sorenson, L. Vu, H. Tataria, and M. W. Verbrugge, "Degradation of lithium ion batteries employing graphite negatives and nickel–cobalt–manganese oxide + spinel manganese oxide positives: Part 1, aging mechanisms and life estimation," *Journal of Power Sources*, vol. 269, pp. 937–948, 2014.

[97] A. Hentunen, J. Forsström, S. Jenu, S. Tuurala, A. Manninen, and S. Bjarghov, "Smart system of renewable energy storage based on INtegrated EVs and bAtteries to empower mobile, Distributed and centralised Energy storage in the distribution grid - INVADE D6.2 Battery techno-economics tool," Horizon 2020 project deliverable, 2018.

[98] I. Laresgoiti, S. Käbitz, M. Ecker, and D. U. Sauer, "Modeling mechanical degradation in lithium ion batteries during cycling: Solid electrolyte interphase fracture," *Journal of Power Sources*, vol. 300, pp. 112–122, 2015.

[99] M. Ecker, N. Nieto, S. Käbitz, J. Schmalstieg, H. Blanke, A. Warnecke, and D. U. Sauer, "Calendar and cycle life study of li(NiMnCo)o2-based 18650 lithium-ion batteries," *Journal of Power Sources*, vol. 248, pp. 839–851, 2014.

[100] International Electrotechnical Commission (IEC), *IEC TS 61724-2:2016 Photovoltaic system performance –Part 2: Capacity evaluation method*, International Electrotechnical Commission (IEC) Std., 2016.

[101] G. M. Masters, *Renewable and EfficientElectric Power Systems*. John Wiley & Sons, 2004.

[102] H. Karimi, S. Jadid, and H. Saboori, "Multi-objective bi-level optimisation to design real-time pricing for demand response programs in retail markets," *IET Generation, Transmission & Distribution*, vol. 13, no. 8, pp. 1287–1296, 2019.

[103] N. I. Nwulu and X. Xia, "Optimal dispatch for a microgrid incorporating renewables and demand response," *Renewable Energy*, vol. 101, pp. 16–28, 2017.

[104] Q. P. Zheng, J. Wang, P. M. Pardalos, and Y. Guan, "A decomposition approach to the two-stage stochastic unit commitment problem," *Annals of Operations Research*, vol. 210, no. 1, pp. 387–410, 2012.

[105] U.S. National Weather Service, "Global Forecast System (GFS)," https://www.emc.ncep.noaa.gov/emc/pages/numerical_forecast_systems/gfs.php, pristup: 1. rujna 2021.

[106] W. F. Holmgren, C. W. Hansen, and M. A. Mikofski, "pvlib python: a python package for modeling solar energy systems," *Journal of Open Source Software*, vol. 3, no. 29, p. 884, 2018.

[107] Sandia National Laboratories, "PVPerformance Modeling Collaborative," https://pvpmc.sandia.gov/, pristup: 2. rujna 2021.

[108] G. S. Campbell and J. Norman, *An Introduction to Environmental Biophysics*. Springer US, 1998.

[109] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.

[110] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, 1997.

[111] J. Zhang, "Gradient descent based optimization algorithms for deep learning models training," *ArXiv*, 2019.

[112] Narodne novine, br. 74/2018., "Mrežna pravila distribucijskog sustava," https://narodne-novine.nn.hr/clanci/sluzbeni/2018_08_74_1539.html, pristup: 3. rujna 2021.

[113] Narodne novine, br. 52/2020., "Izmjene i dopune mrežnih pravila distribucijskog sustava," https://narodne-novine.nn.hr/clanci/sluzbeni/2020_04_52_1053.html, pristup: 3. rujna 2021.

[114] Narodne novine, br. 100/2015., "Zakon o obnovljivim izvorima energije i visokoučinkovitoj kogeneraciji," https://narodne-novine.nn.hr/clanci/sluzbeni/2015_09_100_1937.html, pristup: 5. rujna 2021.

[115] Narodne novine, br. 123/2016., "Uredba o izmjenama zakona o obnovljivim izvorima energije i visokoučinkovitoj kogeneraciji," https://narodne-novine.nn.hr/clanci/sluzbeni/2016_12_123_2689.html, pristup: 5. rujna 2021.

[116] Narodne novine, br. 131/2017., "Uredba o izmjenama zakona o obnovljivim izvorima energije i visokoučinkovitoj kogeneraciji," https://narodne-novine.nn.hr/clanci/sluzbeni/2017_12_131_3011.html, pristup: 5. rujna 2021.

[117] Narodne novine, br. 111/2018., "Zakon o izmjenama i dopunama Zakona o obnovljivim izvorima energije i visokoučinkovitoj kogeneraciji," https://narodne-novine.nn.hr/clanci/sluzbeni/2018_12_111_2151.html, pristup: 5. rujna 2021.

[118] HEP Elektra d.o.o., "Tarifne stavke (cijene) za crveni tarifni model za kategoriju kupaca kućanstvo," https://www.hep.hr/elektra/kucanstvo/tarifne-stavke-cijene/1547, pristup: 1. listopada 2021.

[119] Narodne novine, br. 112/2018., "Odluka o iznosu tarifnih stavki za distribuciju električne energije," https://narodne-novine.nn.hr/clanci/sluzbeni/2018_12_112_2185.html, pristup: 1. listopada 2021.

[120] Narodne novine, br. 112/2018., "Odluka o iznosu tarifnih stavki za prijenos električne energije," https://narodne-novine.nn.hr/clanci/sluzbeni/2018_12_112_2186.html, pristup: 1. listopada 2021.

[121] Narodne novine, br. 115/2016., "Zakon o izmjenama i dopunama Zakona o porezu na dodanu vrijednost," https://narodne-novine.nn.hr/clanci/sluzbeni/2016_12_115_2526.html, pristup: 2. listopada 2021.

[122] HEP - Operator distribucijskog sustava d.o.o., "Tarifne stavke (cijene) za crveni tarifni model za kateogriju kupaca kućanstvo," https://www.hep.hr/ods/korisnici/kucanstvo/tarifne-stavke-cijene/160, pristup: 3. listopada 2021.

[123] HEP Elektra d.o.o., "Tarifni modeli za kategoriju kupaca kućanstvo," https://www.hep.hr/elektra/kucanstvo/tarifni-modeli/1577, pristup: 3. listopada 2021.

[124] Institute of Electrical and Electronics Engineers (IEEE), "The IEEE European Low Voltage Test Feeder," https://site.ieee.org/pes-testfeeders/resources/, pristup: 5. listopada 2021.

[125] Victron Energy B.V., "MultiPlus Inverter/Charger C 24/800/16 datasheet," https://www.victronenergy.com/upload/documents/Datasheet-MultiPlus-inverter-charger--800VA-5kVA-EN-.pdf, pristup: 6. listopada 2021.

[126] Luxor Solar GmbH, "LX-310-330W Mono/ 158-60+ Black Frame datasheet," https://www.luxor.solar/files/luxor/download/datasheets/LX_EL_M60_BF_310-330W_1665x1002x35_158cs_en_low.pdf, pristup: 6. listopada 2021.

[127] SMA Solar Technology AG, "SMA Sunny Highpower Peak3 datasheet," https://files.sma.de/downloads/SHP-20-DS-en-22.pdf, pristup: 7. listopada 2021.

[128] SMA Solar Technology AG, "Technical Information Efficiency and Derating SUNNY BOY / SUNNY BOY STORAGE /SUNNY TRIPOWER / SUNNY MINI CENTRAL /SUNNY HIGHPOWER," https://files.sma.de/downloads/WirkungDerat-TI-en-49.pdf, pristup: 8. listopada 2021.

[129] Himoinsa S.L., "Himoinsa HFW-245 T5 datasheet," https://www.himoinsa.com/eng/electric-generators/19669/generator-set--250kva--mobile.html, pristup: 9. listopada 2021.

[130] Hrvatski autoklub (HAK), "Cijene goriva," https://www.hak.hr/info/cijene-goriva/#li_eurodizel, pristup: 15. rujna 2021.

[131] Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, Laboratorij za obnovljive izvore energije, "Online baza podataka mjerenja," https://reslab.ferit.hr/?measurements, pristup: 10. listopada 2021.

[132] F. Chollet *et al.*, "Keras," https://keras.io, pristup: 11. listopada 2021.

[133] T. Dozat, "Incorporating nesterov momentum into adam," in *ICLR 2016 Workshop*, 2016.

[134] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *CoRR*, vol. abs/1412.6980, 2015.

Popis slika

2.1 Operacijske strategije mikromreže 6
2.2 Arhitektura upravljačkog sustava mikromreže 9

3.1 Strategija pomičnog horizonta s korektivnim djelovanjem 34
3.2 Blokovska shema dvoslojnog adaptivnog sustava upravljanja energijom mikromreže 35
3.3 Blokovska shema kosimulacijskog okruženja nižeg sloja sustava upravljanja energijom mikromreže 40
3.4 Određivanje položaja i osvježavanje brzine čestice 42
3.5 Struktura OpenDSS alata 44

4.1 Blokovska shema jednosabirničkog modela mikromreže 46
4.2 Blokovska shema modela baterijskog sustava pohrane energije 50
4.3 Učinkovitost dvosmjernog pretvarača energetske elektronike ovisne o opterećenju 52
4.4 Grafički prikaz linearizacije funkcije pomoću više linearnih odsječaka 53
4.5 Linearna aproksimacija učinkovitosti dvosmjernog pretvarača energetske elektronike ovisne o opterećenju pomoću više odsječaka 53
4.6 Modeli punjenja litij-ionskih baterija 55
4.7 $\Delta SOE/SOE$ karakteristika energetskog modela punjenja litij-ionskih baterija 56
4.8 Karakteristika faktora stresa kalendarskog starenja baterije 60
4.9 Karakteristika gubitka životnog vijeka baterije uslijed cikličkog starenja . . 65
4.10 Blokovska shema modela baterijskog sustava pohrane energije 66
4.11 Linearizacija funkcije troška goriva upravljivog generatora 71
4.12 Upravljanje potrošnjom statički upravljivog trošila 73
4.13 Upravljanje potrošnjom dinamički upravljivog trošila 74
4.14 Princip rada vremenski odgodivog trošila 75
4.15 Prognoza snage globalnog horizontalnog sunčevog zračenja i temperature okoliša za mikrolokaciju zgrade FERIT-a Osijek za razdoblje od 31. prosinca 2021. 00:00 sati do 2. siječnja 2022. 00:00 sati pomoću GFS servisa 87

4.16 Struktura LSTM ćelije 88

5.1 Postavke optimizacijskog okvira korištenog za vrednovanje dvoslojnog sustava upravljanja energijom 94
5.2 Jedinični trošak/vrijednost preuzete/predane električne energije opskrbljivaču tijekom jednog dana za referentni slučaj 99
5.3 Jednofazna shema testnog sustava IEEE European Low Voltage Test Feeder 101
5.4 Jednofazna shema testne mikromreže integrirane u testni sustav IEEE European Low Voltage Test Feeder za referentni slučaj 102
5.5 Linearna aproksimacija učinkovitosti dvosmjernog pretvarača energetske elektronike Victron MultiPlus C 24/800/16 korištena za referentni slučaj 103
5.6 Linearna aproksimacija karakteristike $\Delta SOE/SOE$ prilikom procesa punjenja litij-ionskog baterijskog članka Sony US18650VTC5 pri faktoru 1C korištena za referentni slučaj 105
5.7 Linearna aproksimacija nelinearne karakteristike učinkovitosti izmjenjivača SMA Sunny Highpower Peak3 SHP 150-20 pri različitim opterećenjima korištena za referentni slučaj 109
5.8 Trošak goriva i jedinični trošak goriva upravljivog generatora za različite izlazne snage za referentni slučaj 111
5.9 Profil izmjerene snage neupravljive potrošnje testne mikromreže 112
5.10 Usporedba izmjerenog i planiranog profila snage potrošnje statički upravljivog trošila u obliku klimatizacijskog sustava s 5 jedinica za referentni slučaj . . . 113
5.11 Planirani profil snage potrošnje vremenski odgodivog trošila u obliku električnog automobila za referentni slučaj 115
5.12 Ulazni meteorološki parametri u umjetnu neuronsku mrežu 117
5.13 Shematski prikaz umjetne neuronske mreže s dugom kratkoročnom memorijom korištene za predviđanje ulaznih parametara u optimizacijske probleme slojeva sustava upravljanja energijom za referentni slučaj 119
5.14 Srednja apsolutna pogreška kroz epohe tijekom treniranja umjetne neuronske mreže na skupu za treniranje i skupu za validaciju 121
5.15 Rezultat predviđanja profila snage potrošnje mikromreže za prvi korak u budućnosti za cijeli testni skup 122
5.16 Odnos predviđene i stvarne potrošnje mikromreže za prvi korak u budućnosti za cijeli testni skup 122

5.17 Srednja apsolutna pogreška MAE, korijen srednje kvadratne pogreške $RMSE$ i koeficijent korelacije R za sve pojedine vremenske korake predviđanja u budućnosti za cijeli horizont predviđanja 123
5.18 Rezultati predviđanja profila snage potrošnje mikromreže za ljetni radni dan 124
5.19 Odnos predviđene i stvarne snage potrošnje električne energije mikromreže za ljetni radni dan 124
5.20 Rezultati predviđanja profila snage potrošnje mikromreže za ljetni radni dan u više iteracija 125
5.21 Rezultati predviđanja profila snage potrošnje mikromreže za ljetni vikend dan u više iteracija 126
5.22 Srednja apsolutna pogreška kroz epohe tijekom treniranja umjetnih neuronskih mreža ANN1, ANN2 i ANN3 na skupu za treniranje i skupu za validaciju 128
5.23 Rezultat predviđanja profila snage potrošnje mikromreže za cijeli testni skup pomoću umjetne neuronske mreže ANN1 129
5.24 Odnos predviđene i stvarne snage potrošnje električne mikromreže za cijeli testni skup pomoću umjetne neuronske mreže ANN1 130
5.25 Srednja apsolutna pogreška MAE, korijen srednje kvadratne pogreške $RMSE$ i koeficijent korelacije R za sve pojedine vremenske korake predviđanja u budućnosti za cijeli horizont predviđanja pomoću umjetne neuronske mreže ANN1 131
5.26 Odnos predviđene i stvarne snage potrošnje električne energije mikromreže pomoću umjetne neuronske mreže ANN1 za svaki vremenski korak predviđanja u budućnosti na cijelom testnom skupu 132
5.27 Tokovi snaga u mikromreži u promatranom horizontu planiranja za sva četiri podslučaja 139
5.28 Profil preuzimanja/predaje električne energije iz/u nadređenu elektroenergetsku mrežu u promatranom horizontu planiranja za sva četiri podslučaja . . 140
5.29 Profil punjenja i pražnjenja baterijskog sustava pohrane energije u promatranom horizontu planiranja za sva četiri podslučaja 141
5.30 Pokazatelj vlastite potrošnje i pokazatelj samodostatnosti opskrbe u promatranom horizontu planiranja za sva četiri podslučaja 145
5.31 Usporedba predviđanja ulaznih parametara u optimizacijske probleme (slojeve) sa stvarnim mjerenjima 147

5.32 Profil snage preuzimanja i predaje električne energije iz/u nadređenu elektroenergetsku mrežu tijekom promatranog horizonta planiranja za različite iteracije kratkoročnog planiranja pogona testne mikromreže u referentnom slučaju . . . 149
5.33 Profil snage punjenja i pražnjenja baterijskog sustava pohrane energije tijekom promatranog horizonta planiranja za različite iteracije kratkoročnog planiranja pogona mikromreže u referentnom slučaju . . . 150
5.34 Iznosi napona na sabirnicama testne mikromreže tijekom promatranog horizonta planiranja . . . 153
5.35 Opterećenje grana (kabela) u testnoj mikromreži tijekom promatranog horizonta planiranja . . . 154
5.36 Profil snage preuzimanja i predaje električne energije iz/u nadređenu elektroenergetsku mrežu u promatranom horizontu planiranja za sva tri podslučaja . . . 156
5.37 Profil punjenja i pražnjenja baterijskog sustava pohrane energije u promatranom horizontu planiranja za sva tri podslučaja . . . 157
5.38 Analiza osjetljivosti vrijednosti funkcije cilja na postavke elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu), postavke baterijskog sustava pohrane energije i postavke fotonaponskog sustava . . . 161
5.39 Analiza osjetljivosti neto vrijednosti svih pogonskih prihoda/troškova na postavke elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu), postavke baterijskog sustava pohrane energije i postavke fotonaponskog sustava . . . 162
5.40 Analiza osjetljivosti neto vrijednosti svih dodatnih (virtualnih) prihoda/troškova na postavke elementa mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu), postavke baterijskog sustava pohrane energije i postavke fotonaponskog sustava . . . 163

P.1 Rezultat predviđanja profila snage sunčevog zračenja za jedan dan iz skupa za testiranje pomoću umjetne neuronske mreže ANN2 . . . 190
P.2 Rezultat predviđanja profila temperature okoliša za jedan dan iz skupa za testiranje pomoću umjetne neuronske mreže ANN3 . . . 191
P.3 Odnos predviđene i stvarne snage sunčevog zračenja za cijeli testni skup pomoću umjetne neuronske mreže ANN2 . . . 191

P.4 Odnos predviđene i stvarne temperature okoliša za cijeli testni skup pomoću umjetne neuronske mreže ANN3 192
P.5 Srednja apsolutna pogreška MAE, korijen srednje kvadratne pogreške $RMSE$ i koeficijent korelacije R za sve pojedine vremenske korake predviđanja u budućnosti za cijeli horizont predviđanja pomoću umjetne neuronske mreže ANN2 192
P.6 Srednja apsolutna pogreška MAE, korijen srednje kvadratne pogreške $RMSE$ i koeficijent korelacije R za sve pojedine vremenske korake predviđanja u budućnosti za cijeli horizont predviđanja pomoću umjetne neuronske mreže ANN3 193
P.7 Odnos predviđene i stvarne snage sunčevog zračenja pomoću umjetne neuronske mreže ANN2 za svaki vremenski korak predviđanja u budućnosti na cijelom testnom skupu 194
P.8 Odnos predviđene i stvarne temperature okoliša pomoću umjetne neuronske mreže ANN3 za svaki vremenski korak predviđanja u budućnosti na cijelom testnom skupu 195
P.9 Profil bez odgode i odgođeni profil potrošnje električne energije vremenski-odgodivog trošila u promatranom horizontu planiranja za sva četiri podslučaja 196
P.10 Profil bez i sa rasterećenjem potrošnje električne energije statički upravljivog trošila u promatranom horizontu planiranja za sva četiri podslučaja 197
P.11 Snaga preuzimanja/predaje radne i jalove snage između testne mikromreže i nadređene elektroenergetske mreže tijekom promatranog horizonta planiranja 198
P.12 Snaga razmjene radne i jalove snage između testne mikromreže i nadređene elektroenergetske mreže, snaga (radna i jalova) opterećenja ostatka niskonaponskog izvoda i snaga (radna i jalova) iz referentnog čvora testnog sustava (nadređena mreža) tijekom promatranog horizonta planiranja 199
P.13 Gubici radne i jalove snage unutar testne mikromreže tijekom promatranog horizonta planiranja 200

Popis tablica

5.1 Iznosi korištenih stavki za izračun jediničnog troška preuzete električne energije od opskrbljivača za referentni slučaj 97
5.2 Iznosi parametara modela mreže (mjesta priključka mikromreže na nadređenu elektroenergetsku mrežu) za referentni slučaj 100
5.3 Koordinate točaka linearne aproksimacije nelinearne karakteristike učinkovitosti dvosmjernog pretvarača energetske elektronike za referentni slučaj 104
5.4 Koordinate točaka linearne aproksimacije nelinearne karakteristike $\Delta SOE/SOE$ za referentni slučaj 105
5.5 Koordinate točaka linearne aproksimacije nelinearne funkcije gubitka životnog vijeka uslijed cikličkog starenja za referentni slučaj 107
5.6 Iznosi parametara modela baterijskog sustava pohrane energije za referentni slučaj 107
5.7 Učinkovitost izmjenjivača SMA Sunny Highpower Peak3 SHP 150-20 za različita opterećenja pretvarača 108
5.8 Koordinate točaka linearne aproksimacije nelinearne karakteristike učinkovitosti izmjenjivača fotonaponskog sustava za referentni slučaj 109
5.9 Iznosi parametara modela fotonaponskog sustava za referentni slučaj 109
5.10 Potrošnja goriva dizelskog agregata za različite izlazne snage 110
5.11 Trošak goriva i jedinični trošak goriva upravljivog generatora za različite izlazne snage za referentni slučaj 111
5.12 Iznosi parametara modela upravljivog generatora za referentni slučaj 112
5.13 Iznosi parametara modela statički upravljivog i vremenski odgodivog trošila za referentni slučaj 115
5.14 Karakteristike umjetnih neuronskih mreža s dugom kratkoročnom memorijom korištenih za predviđanje ulaznih parametara u optimizacijske probleme slojeva sustava upravljanja energijom 116
5.15 Vrijednosti funkcije cilja višeg sloja sustava upravljanja energijom i neto vrijednost svih pogonskih i dodatnih (virtualnih) prihoda/troškova za promatrani horizont planiranja i promatrane podslučajeve 135

5.16 Vrijednosti pojedinih članova funkcije cilja višeg sloja sustava upravljanja energijom za promatrani horizont planiranja i promatrane podslučajeve . . . 136
5.17 Iznosi izmijenjenih električnih energija pojedinih elemenata mikromreže za promatrani horizont planiranja i promatrane podslučajeve 137
5.18 Analiza osjetljivosti vrijednosti funkcije cilja, neto pogonskih prihoda/troškova i neto dodatnih (virtualnih) prihoda/troškova na postavke elemenata testne mikromreže 160

Popis kratica

Istraživanja u području sustava upravljanja energijom mikromreža

HMI – korisničko sučelje (engl. *Human-Machine Interface*),
SCADA – računalni sustav za nadzor, prikupljanje podataka i upravljanje (engl. *Supervisory Control and Data Acquisition*),
SOC – stanje napunjenosti (engl. *State of Charge*),
CC/CV – konstantna struja/konstantni napon (engl. *Constant current/constant voltage*),
MA – pokretni prosjek (engl. *Moving Average*),
ARIMA – autoregresivni integralni model pokretnih prosjeka.

Unaprijeđeni dvoslojni adaptivni sustav upravljanja energijom mikromreže

PH – horizont predviđanja (engl. *Prediction horizon*),
SH – horizont planiranja (engl. *Scheduling horizon*),
CH – horizont upravljanja (engl. *Control horizon*),
IS – početno stanje (engl. *Initial state*),
FS – krajnje stanje (engl. *Final state*),
OIE – obnovljivi izvori energije,
PSO – optimizacija rojem čestica (engl. *Particle Swarm Optimization*),
API – aplikacijsko programsko sučelje (engl. *Application Programming Interface*).

Optimizacijski problemi dvoslojnog sustava upravljanja energijom mikromreže

PDV – porez na dodanu vrijednost,
SOE – energetsko stanje napunjenosti baterije (engl. *State of Energy*),
DOD – dubina pražnjenja (engl. *Depth of Discharge*),
GHI – snaga globalnog horizontalnog sunčevog zračenja (engl. *Global Horizontal Irradiance*),
DNI – snaga izravnog normalnog sunčevog zračenja (engl. *Direct Normal Irradiance*),
DHI – snaga difuznog horizontalnog sunčevog zračenja (engl. *Diffuse Horizontal Irradiance*),
LSTM – duga kratkoročna memorija (engl. *Long Short-Term Memory*),
MAE – srednja apsolutna pogreška (engl. *Mean Absolute Error*),
RMSE – korijen srednje kvadratne pogreške (engl. *Root Mean Square Error*),
R – koeficijent korelacije (engl. *Correlation coefficient*),

Prilozi

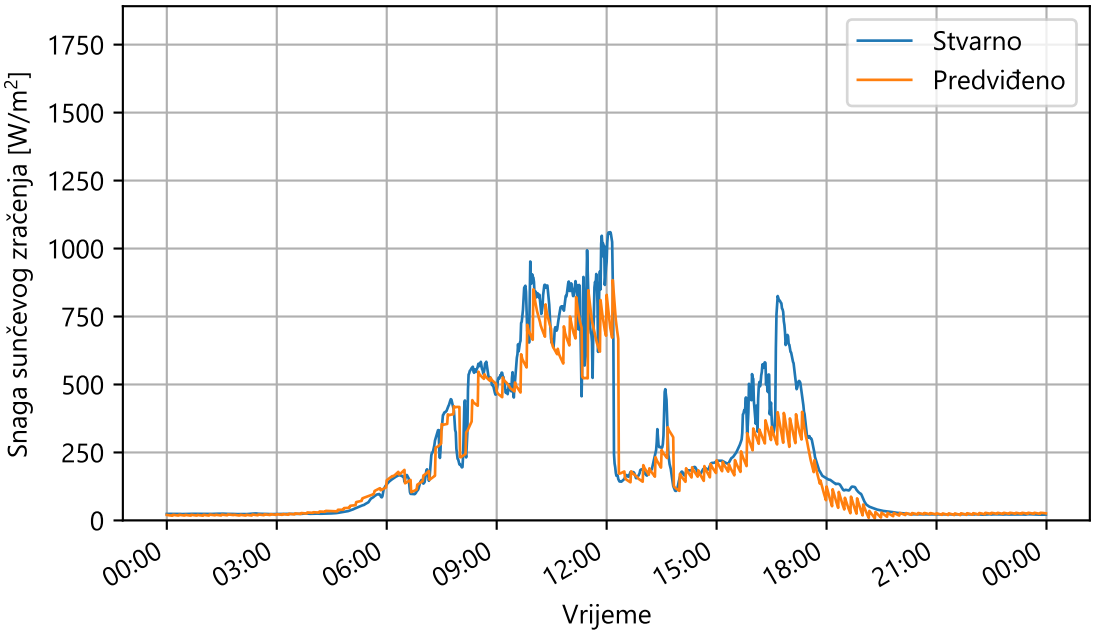

Slika P.1: *Rezultat predviđanja profila snage sunčevog zračenja za jedan dan iz skupa za testiranje pomoću umjetne neuronske mreže ANN2*

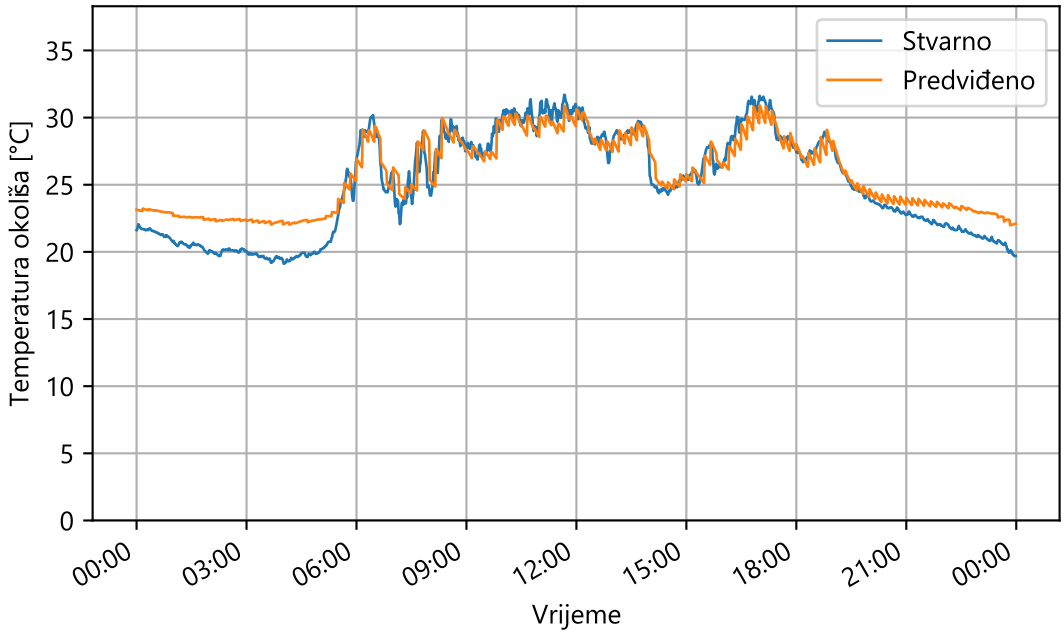

Slika P.2: *Rezultat predviđanja profila temperature okoliša za jedan dan iz skupa za testiranje pomoću umjetne neuronske mreže ANN3*

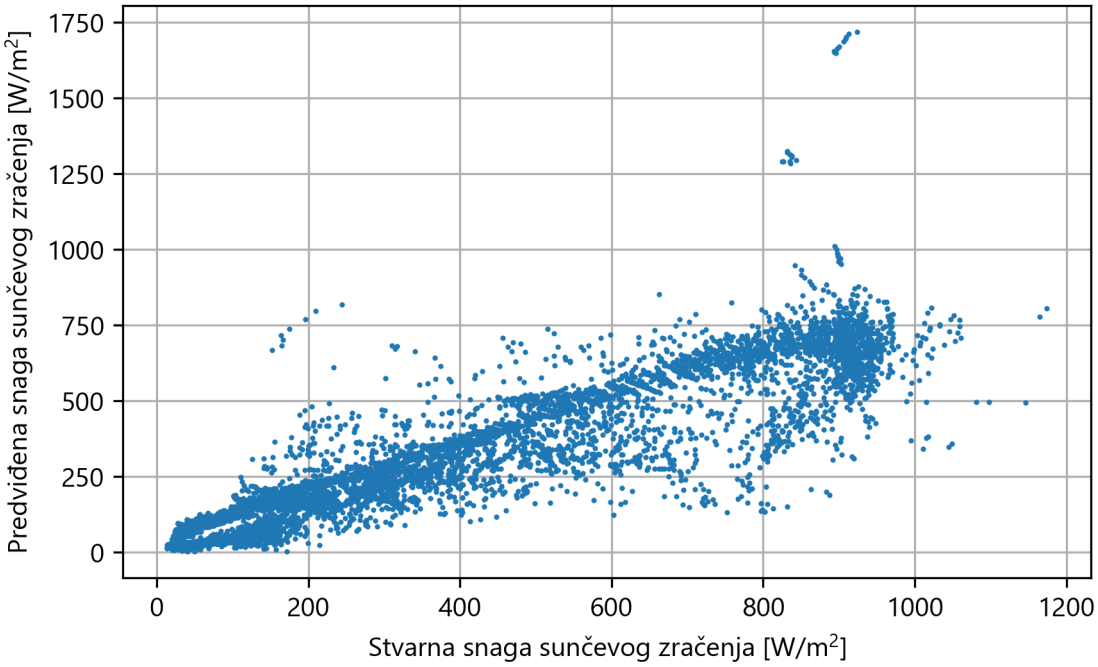

Slika P.3: *Odnos predviđene i stvarne snage sunčevog zračenja za cijeli testni skup pomoću umjetne neuronske mreže ANN2*

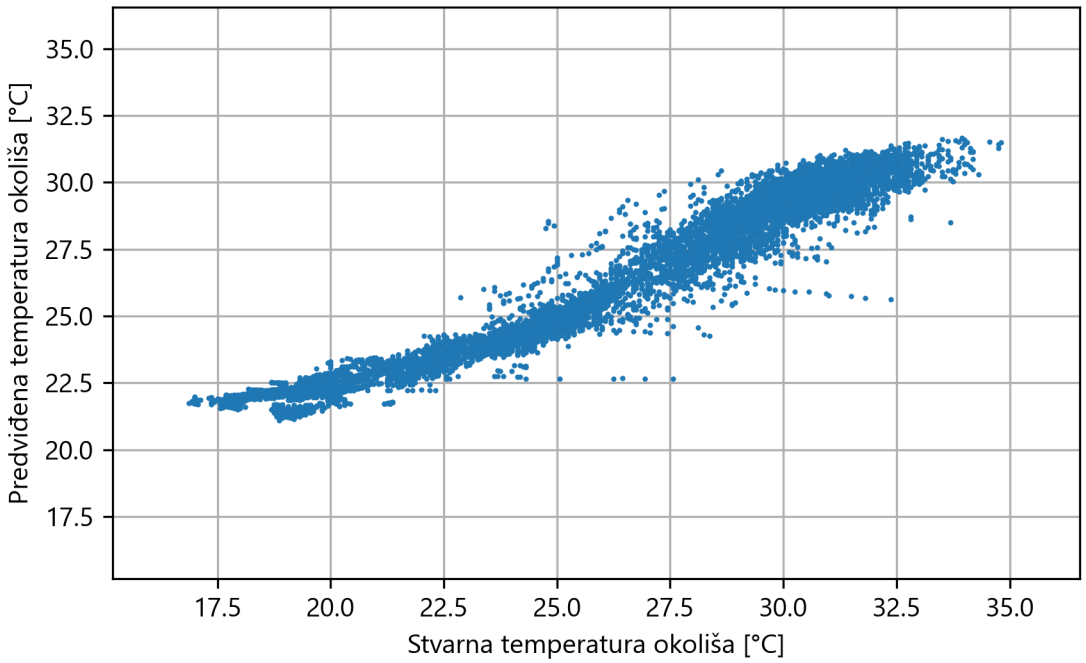

Slika P.4: *Odnos predviđene i stvarne temperature okoliša za cijeli testni skup pomoću umjetne neuronske mreže ANN3*

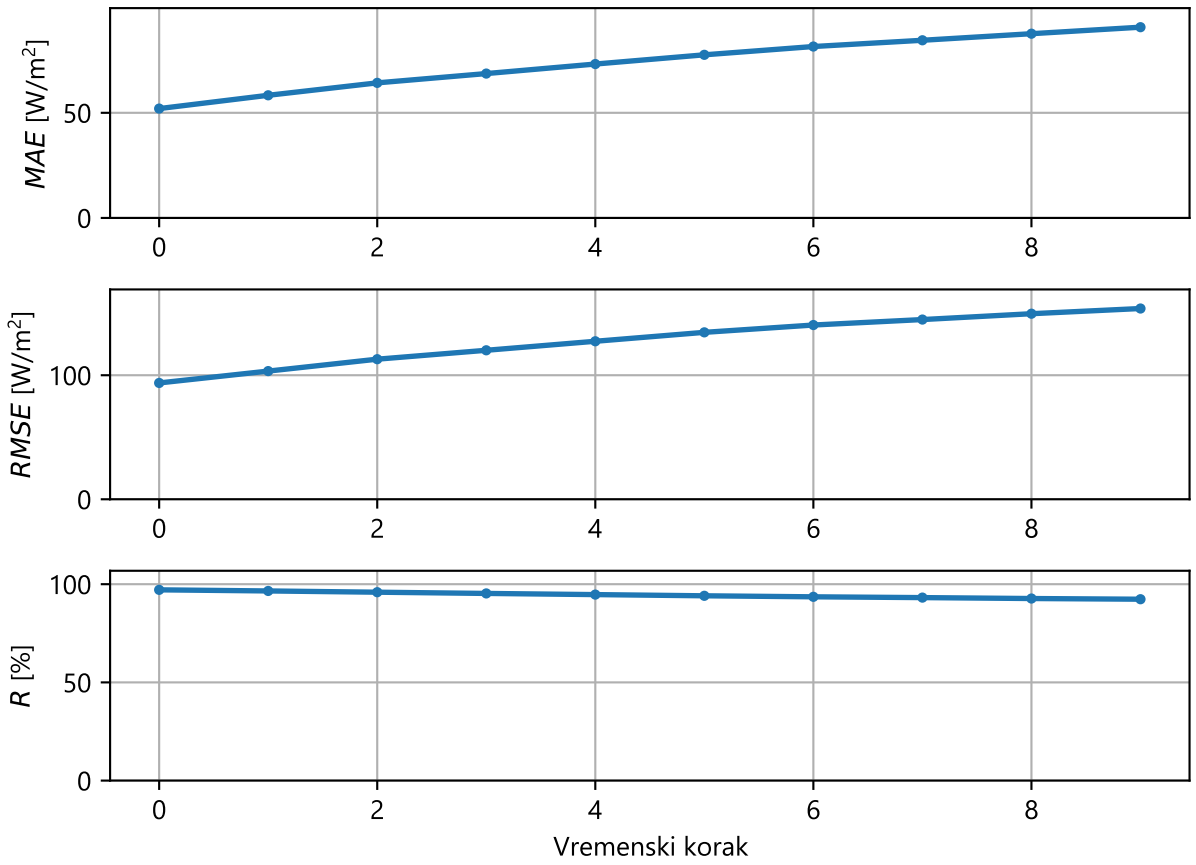

Slika P.5: *Srednja apsolutna pogreška MAE, korijen srednje kvadratne pogreške RMSE i koeficijent korelacije R za sve pojedine vremenske korake predviđanja u budućnosti za cijeli horizont predviđanja pomoću umjetne neuronske mreže ANN2*

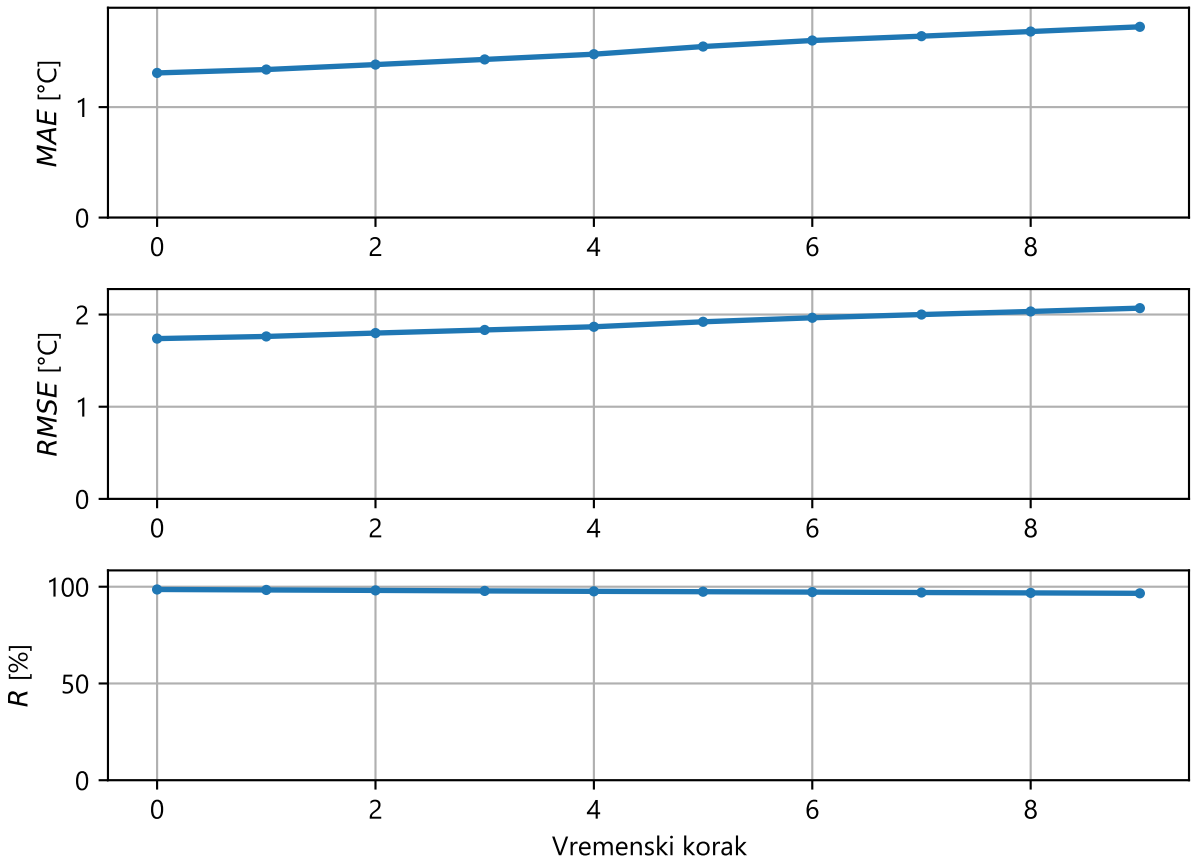

Slika P.6: *Srednja apsolutna pogreška MAE, korijen srednje kvadratne pogreške $RMSE$ i koeficijent korelacije R za sve pojedine vremenske korake predviđanja u budućnosti za cijeli horizont predviđanja pomoću umjetne neuronske mreže ANN3*

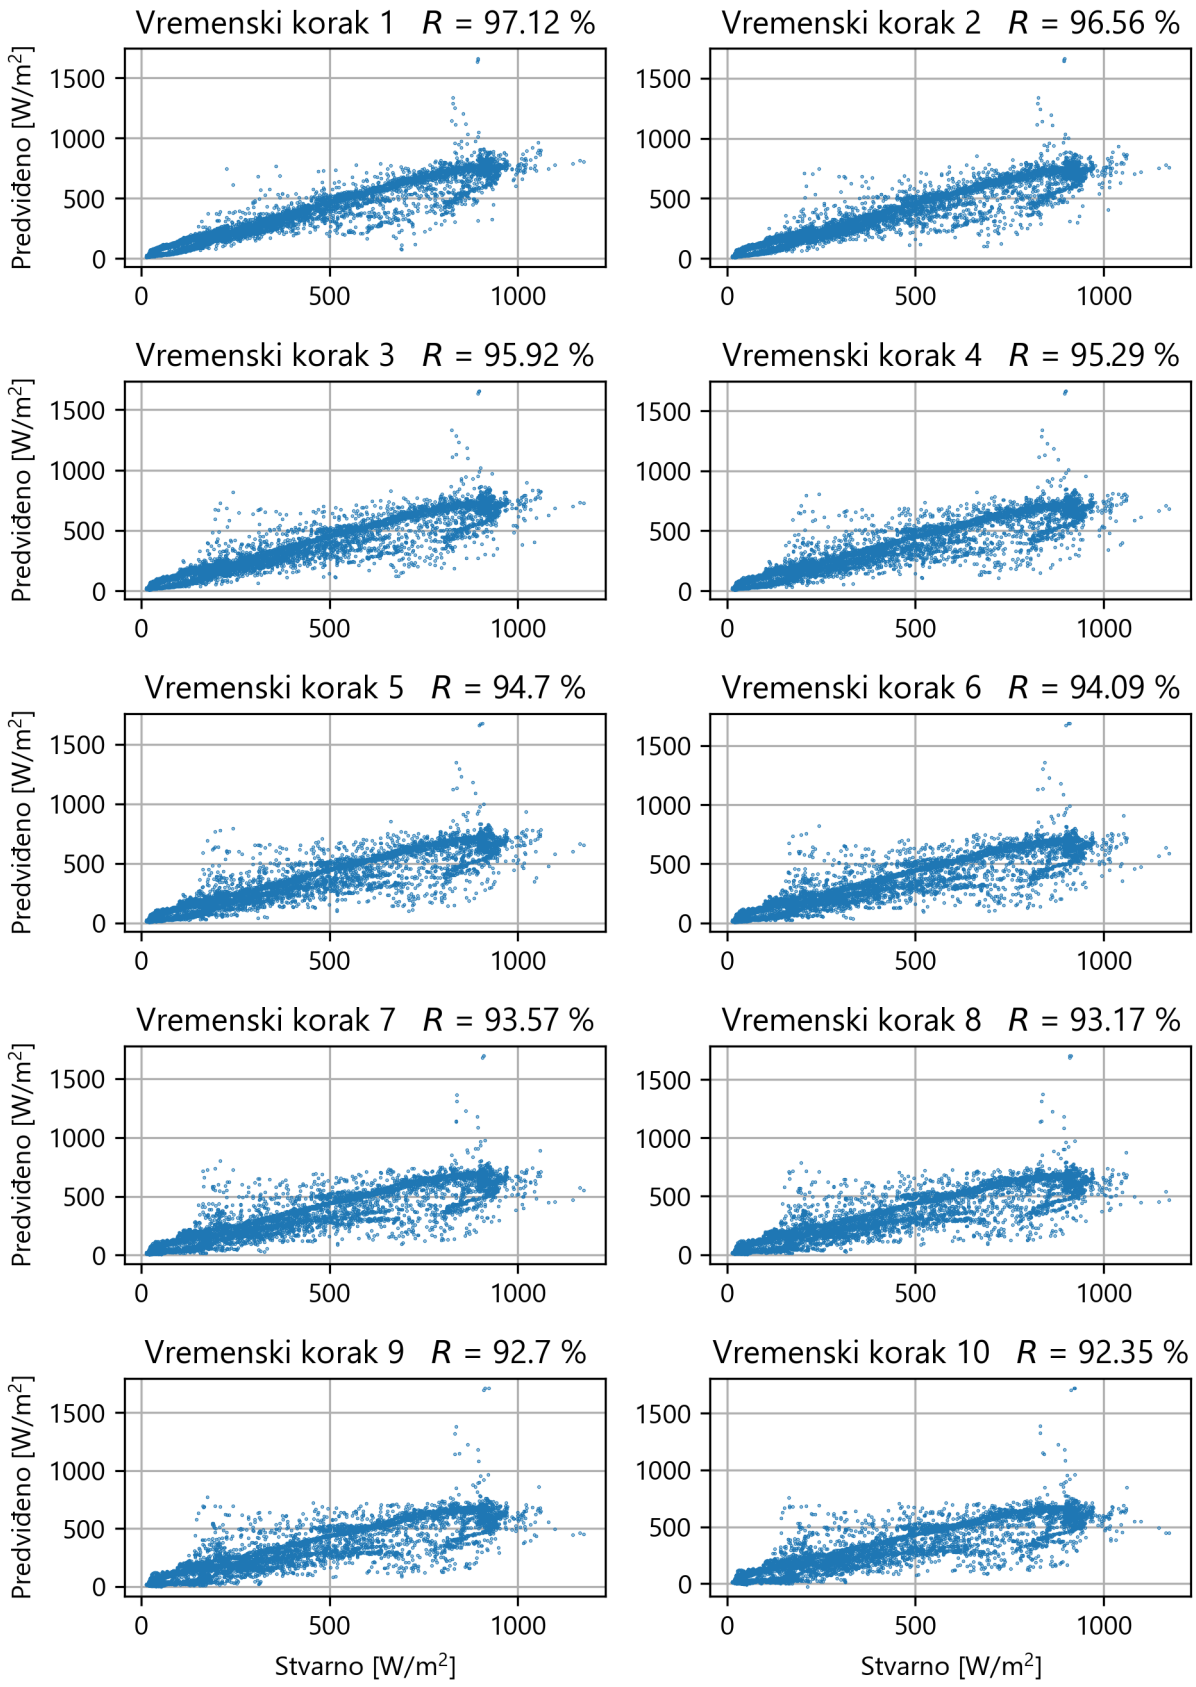

Slika P.7: *Odnos predviđene i stvarne snage sunčevog zračenja pomoću umjetne neuronske mreže ANN2 za svaki vremenski korak predviđanja u budućnosti na cijelom testnom skupu*

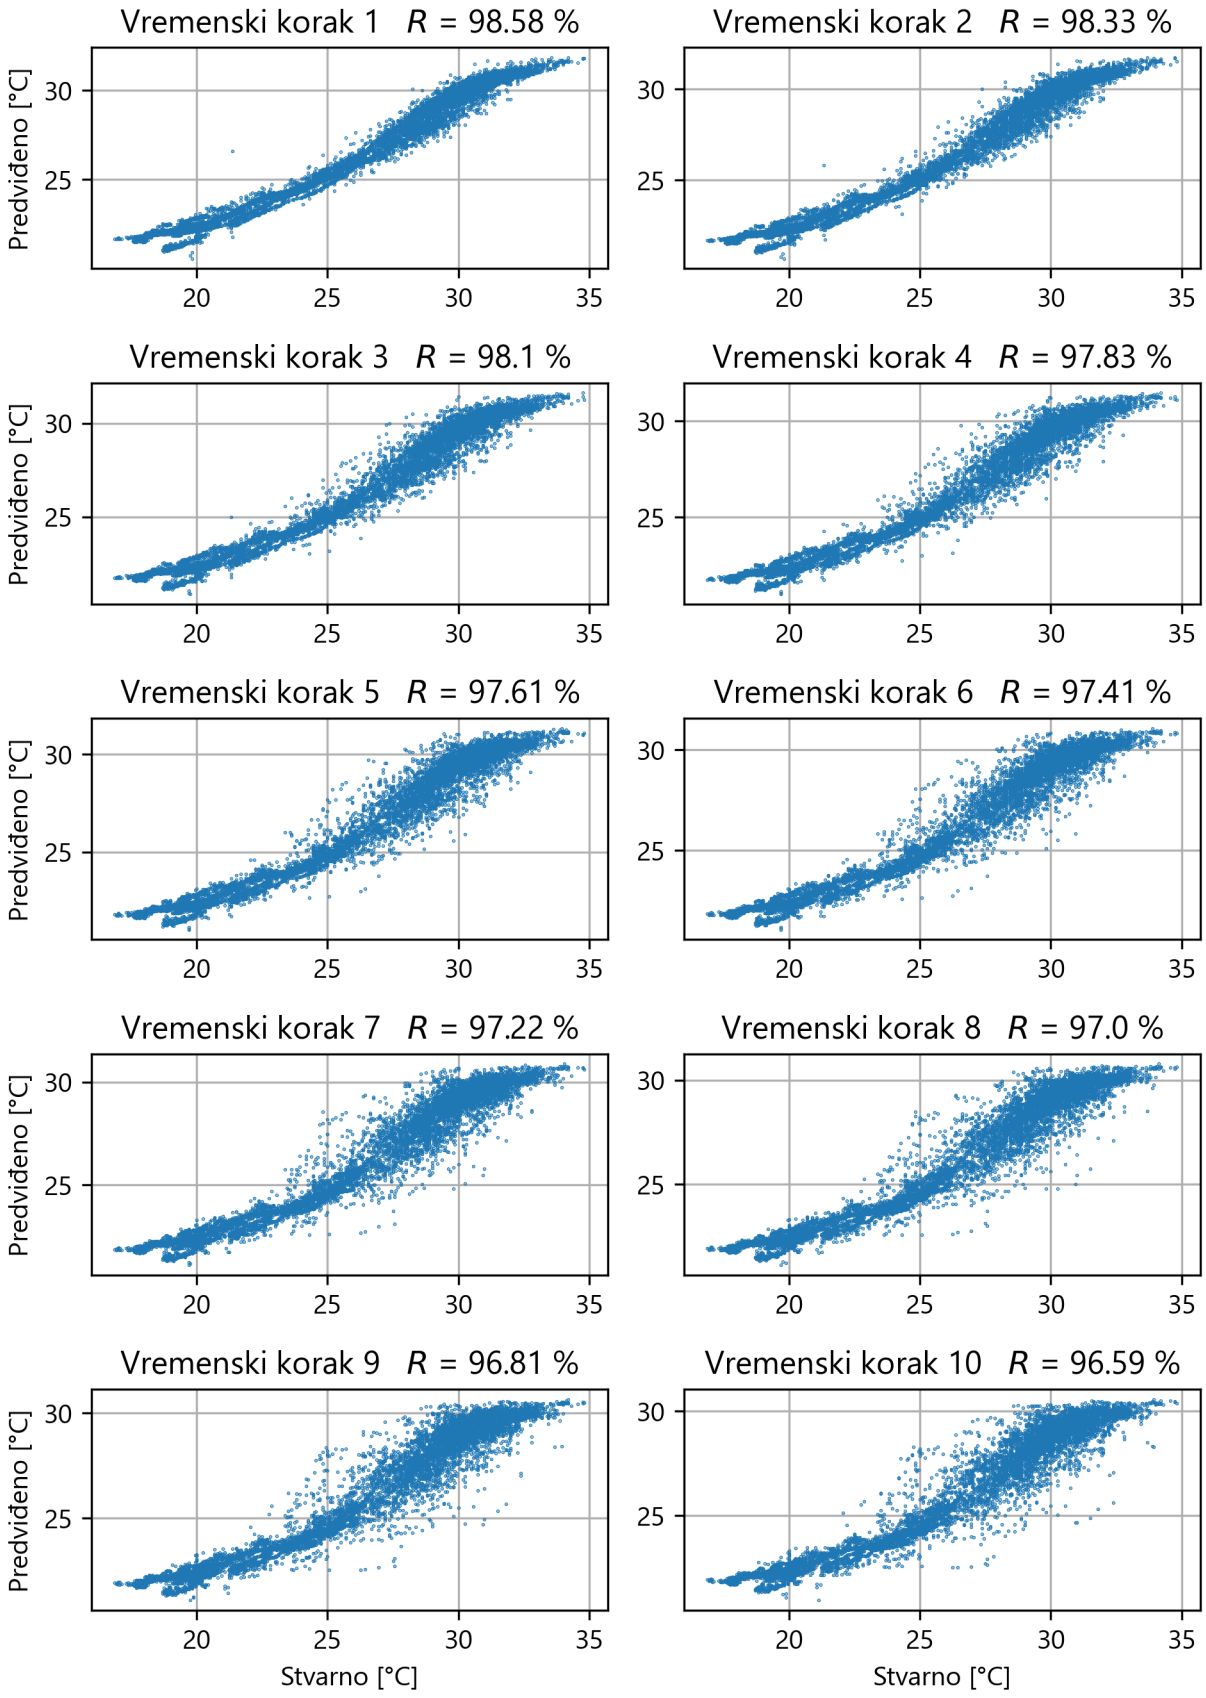

Slika P.8: *Odnos predviđene i stvarne temperature okoliša pomoću umjetne neuronske mreže ANN3 za svaki vremenski korak predviđanja u budućnosti na cijelom testnom skupu*

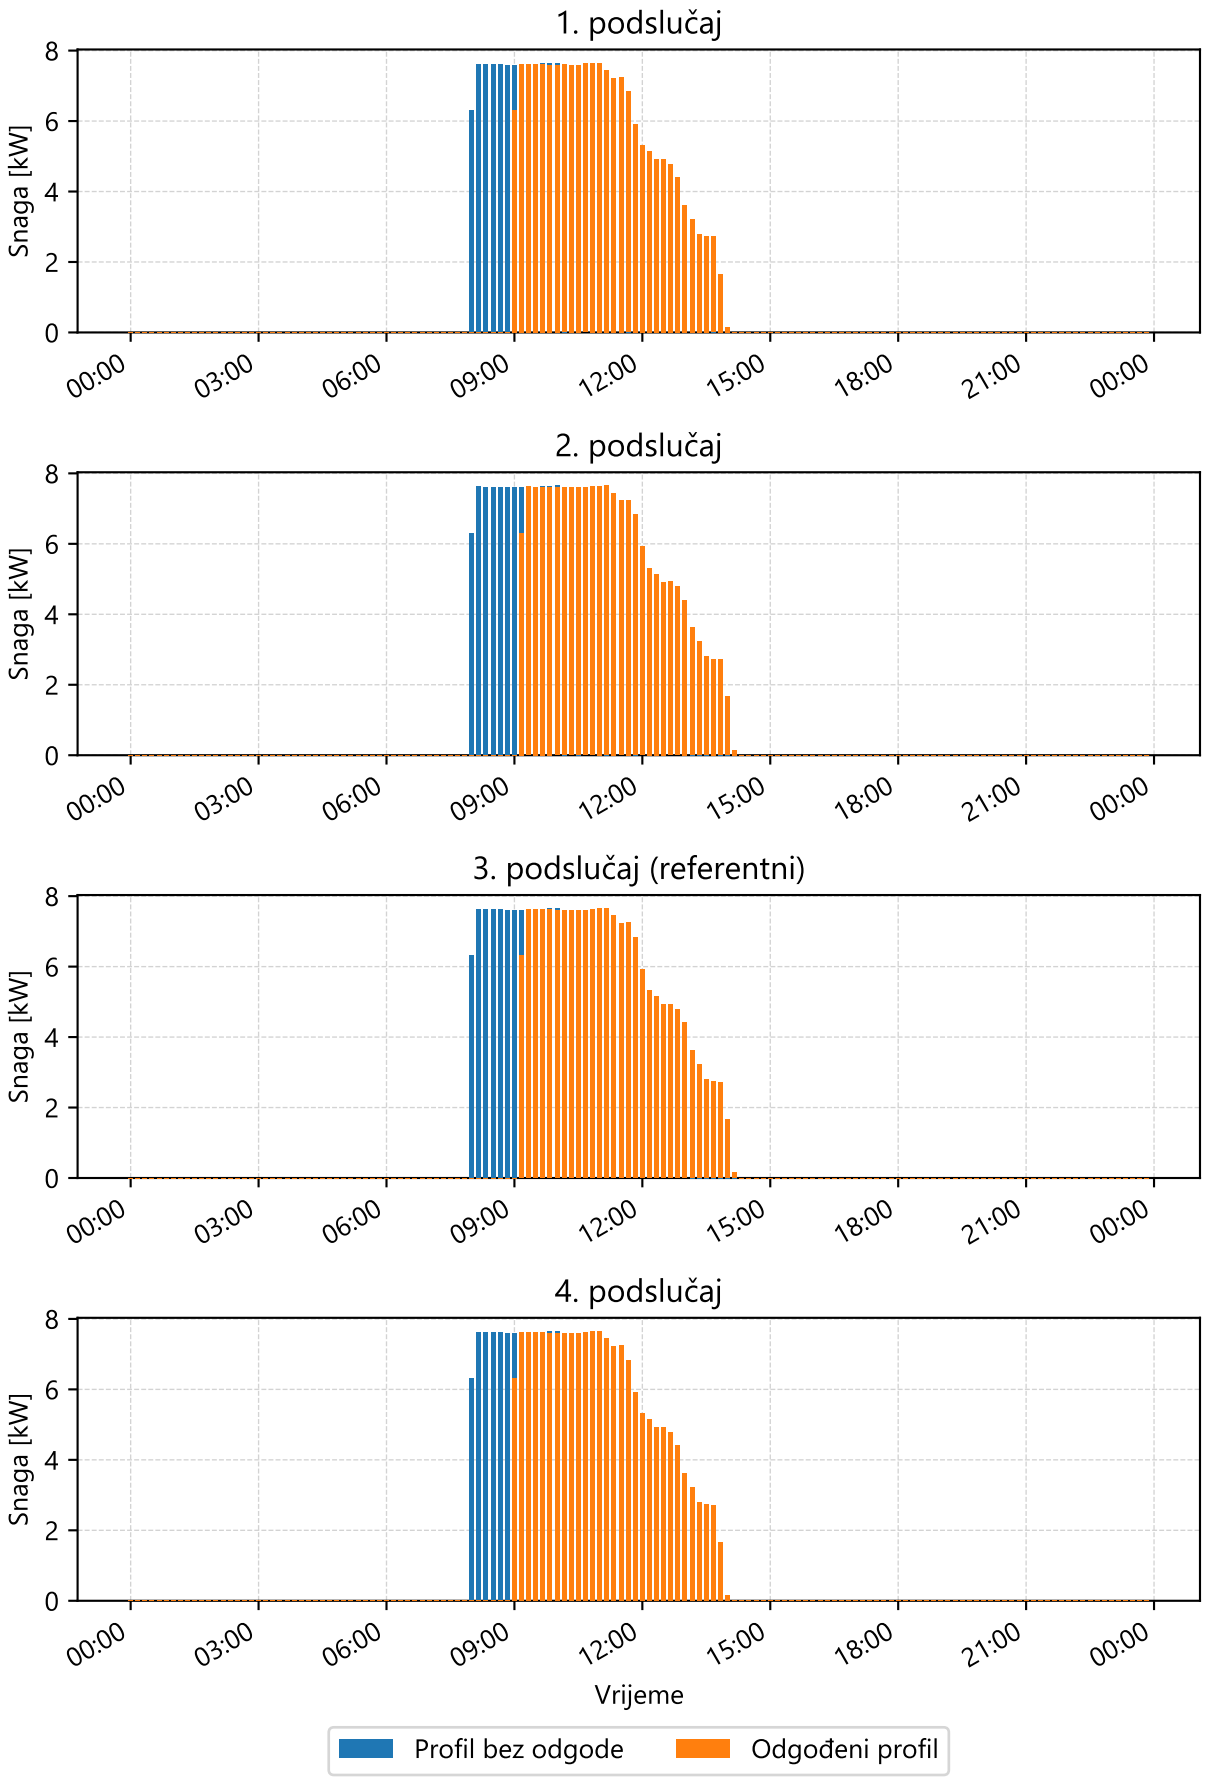

Slika P.9: *Profil bez odgode i odgođeni profil potrošnje električne energije vremenski-odgodivog trošila u promatranom horizontu planiranja za sva četiri podslučaja*

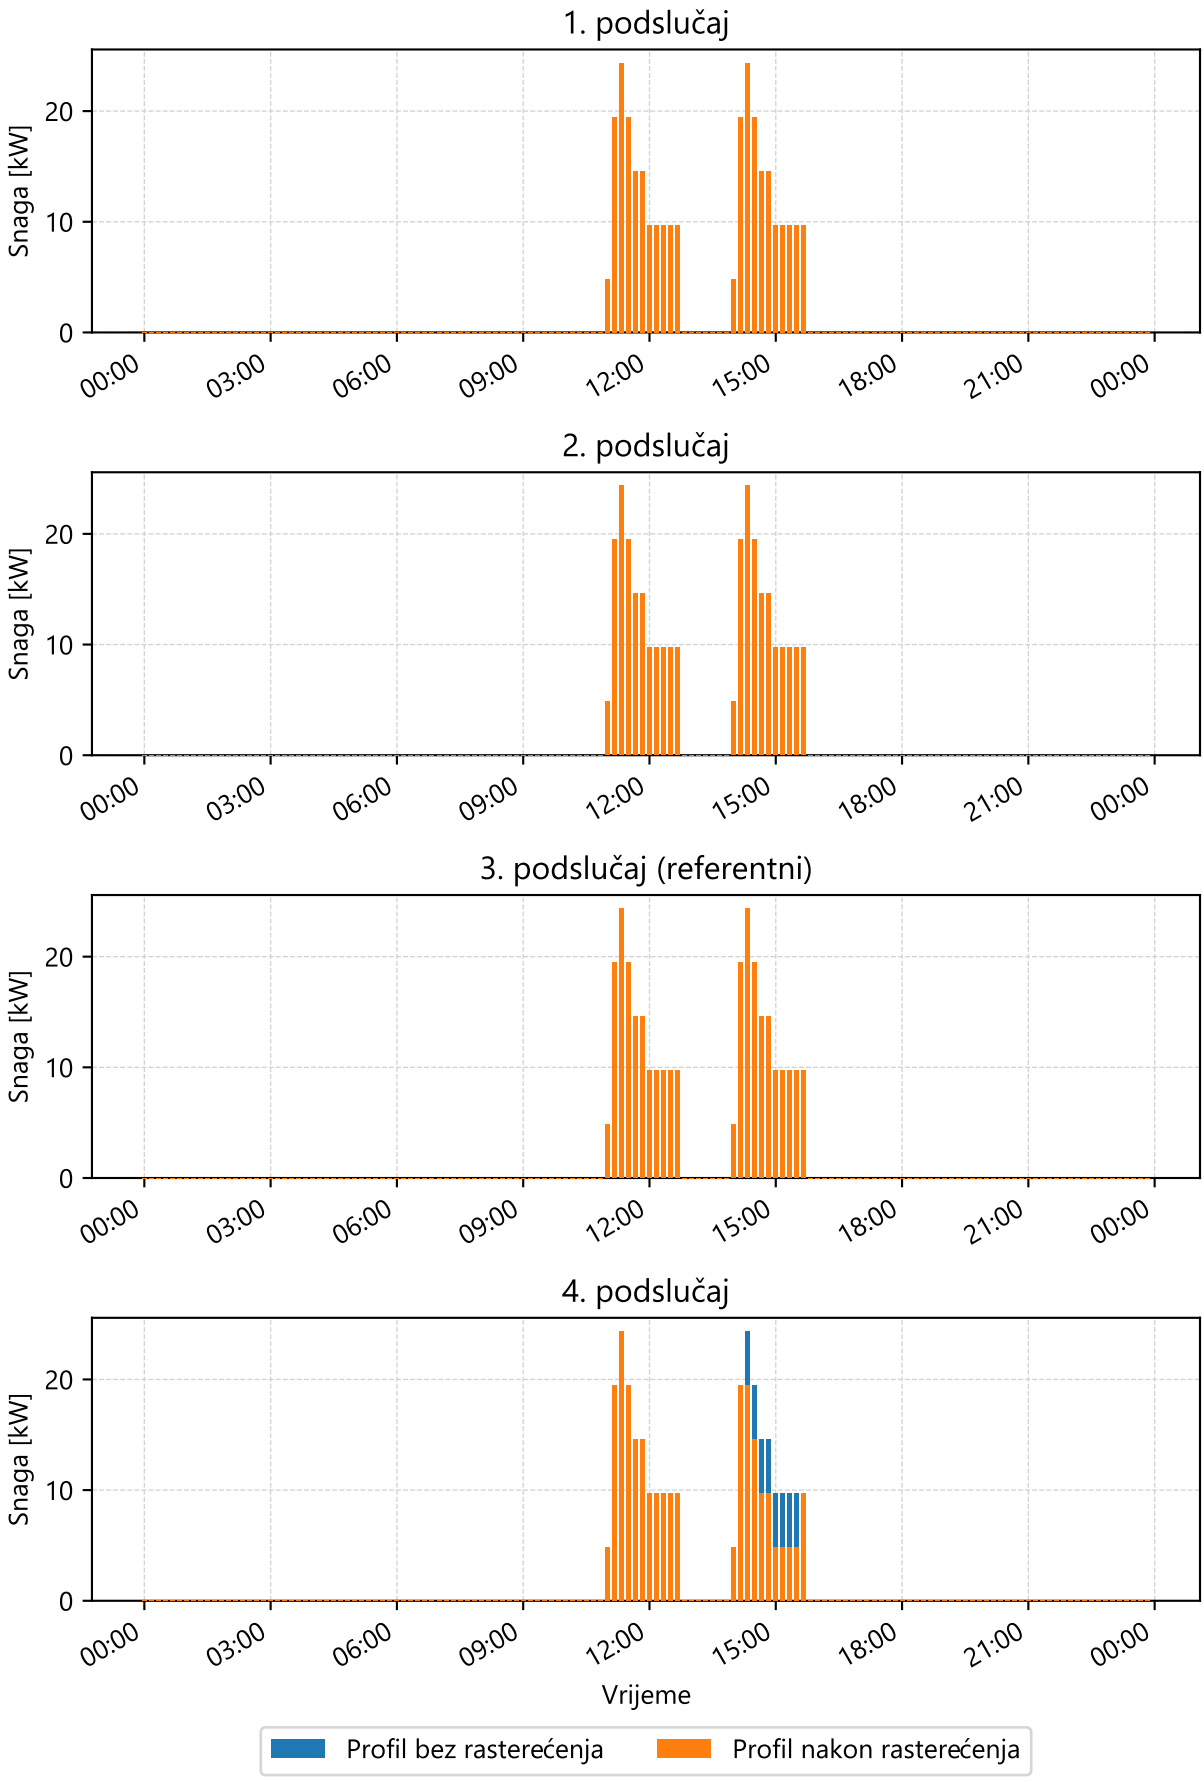

Slika P.10: *Profil bez i sa rasterećenjem potrošnje električne energije statički upravljivog trošila u promatranom horizontu planiranja za sva četiri podslučaja*

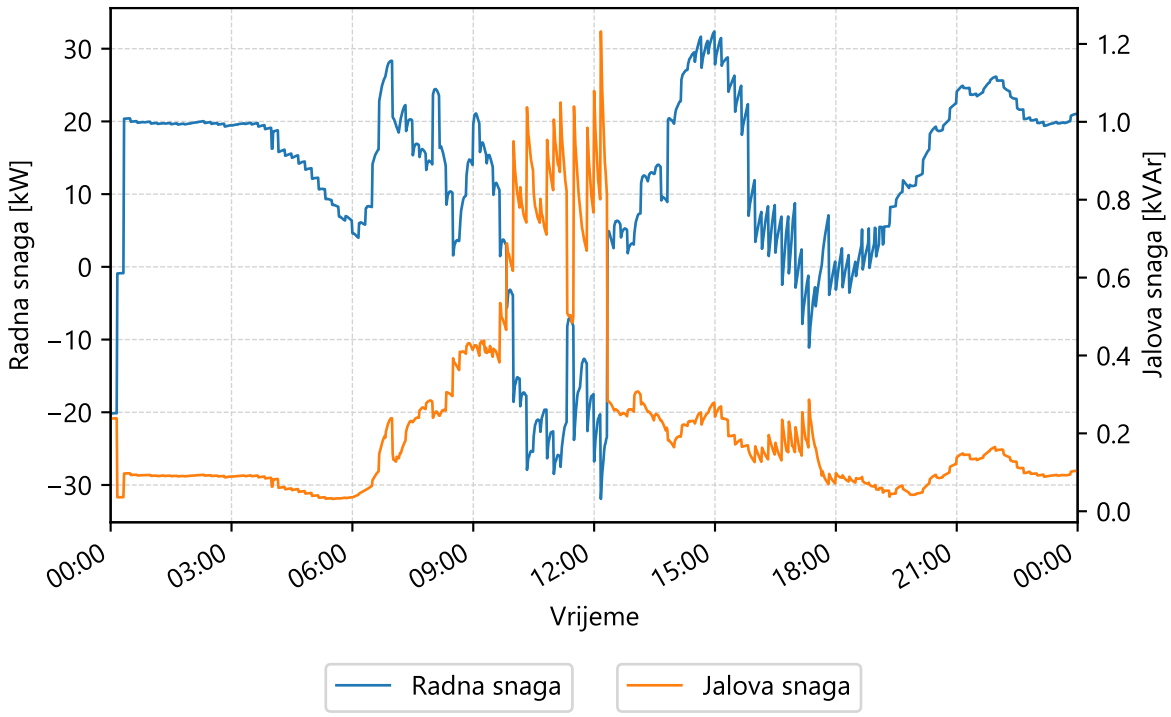

Slika P.11: *Snaga preuzimanja/predaje radne i jalove snage između testne mikromreže i nadređene elektroenergetske mreže tijekom promatranog horizonta planiranja*

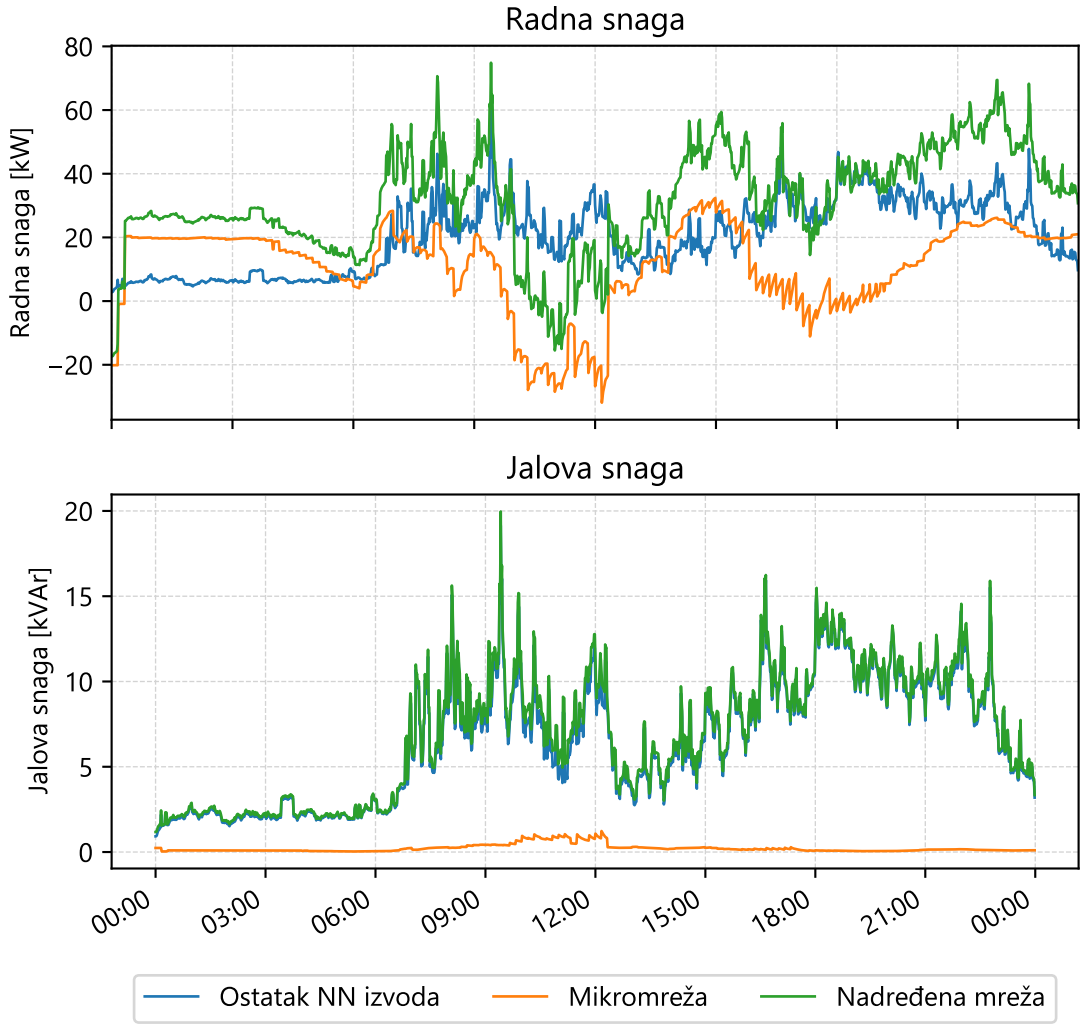

Slika P.12: *Snaga razmjene radne i jalove snage između testne mikromreže i nadređene elektroenergetske mreže, snaga (radna i jalova) opterećenja ostatka niskonaponskog izvoda i snaga (radna i jalova) iz referentnog čvora testnog sustava (nadređena mreža) tijekom promatranog horizonta planiranja*

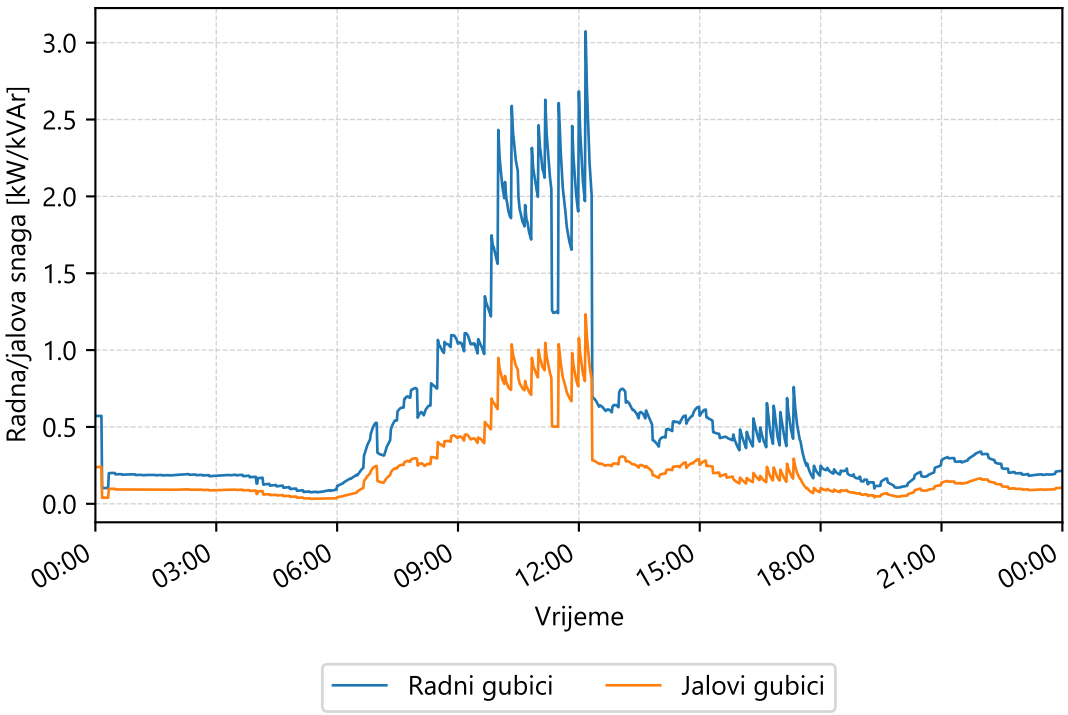

Slika P.13: *Gubici radne i jalove snage unutar testne mikromreže tijekom promatranog horizonta planiranja*

Sažetak

U disertaciji je razvijen i prikazan unaprijeđeni dvoslojni adaptivni sustav upravljanja energijom za kratkoročno planiranje pogona mikromreže. Dvoslojni sustav upravljanja energijom sastoji se od dva međusobno povezana optimizacijska problema (sloja). Viši sloj je realiziran kao mješovito cjelobrojni linearni optimizacijski problem implementiran u okviru strategije pomičnog horizonta s korektivnim djelovanjem i ciljem maksimizacije dobiti mikromreže. Niži sloj je realiziran kao nelinearni optimizacijski problem u kosimulacijskom okruženju koji uvažava električka ograničenja elektroenergetske mreže, a ima tehnički cilj minimizacije odstupanja od planiranih vrijednosti višim slojem (minimizacija korektivnih mjera) u gotovo stvarnom vremenu. Sustav upravljanja energijom ima implementiran unaprijeđeni model baterijskog sustava pohrane energije koji se sastoji od kombiniranja učinkovitosti dvosmjernog energetskog pretvarača ovisne o opterećenju, energetskog modela punjenja baterije, modeliranja cikličkog i kalendarskog starenja baterije i valorizacije pohranjene energije u bateriji. Ulazni podaci u optimizacijske probleme predviđaju se uz pomoć različitih metoda, ovisno o sloju sustava upravljanja energijom i veličini koja se predviđa. Korištene metode podrazumijevaju modele numeričkog predviđanja vremena i umjetne neuronske mreže s dugom kratkoročnom memorijom.

Unaprijeđeni dvoslojni adaptivni sustav upravljanja energijom primijenjen je na planiranje kratkoročnog pogona testne mikromreže na osnovu kojeg su doneseni generalni zaključci da točnost prognoza koje služe kao ulazni podaci uvelike utječe na optimalnost pogona mikromreže. Instalirana snaga vlastitih izvora električne energije u mikromreži uvelike pridonosi stupnju samodostatnosti opskrbe mikromreže i smanjenju pogonskih troškova. Razina složenosti modela baterijskog sustava pohrane energije omogućuje vođenje različitih strategija pogona mikromreže kao kompromis između smanjenja pogonskih troškova i produljenja životnog vijeka opreme.

Ključne riječi: Mikromreža, sustav upravljanja energijom, kratkoročno planiranje pogona, obnovljivi izvori energije, baterijski sustav pohrane energije, optimizacijski problem.

Abstract

An advanced double-layer adaptive energy management system for short-term microgrid operation planning is developed and presented in the thesis. The double-layer energy management system consists of two interconnected optimization problems (layers). The higher layer is realized as a mixed integer linear optimization problem implemented within the rolling horizon strategy with reactive scheduling and the objective function of maximizing the profit of the microgrid. The lower layer is realized as a nonlinear optimization problem in a cosimulation environment that integrates the electrical limitations of the power grid, and has the technical objective of minimizing deviations from the planned values of the higher layer (minimisation of corrective measures) in near real time. The energy management system has implemented an advanced model of battery energy storage system consisting of combining the load-dependent efficiency of a bidirectional power converter unit, battery energy charging model, modeling cycle and calendar aging of the battery and valorization of stored energy in the battery. The input data to the optimization problems are predicted using different methods, depending on the layer of the energy management system and the size that is predicted. The methods used include numerical weather prediction models and artificial neural networks with long short-term memory.

An advanced double-layer adaptive energy management system was applied to the short-term operation planning of the test microgrid, based on which general conclusions were made that the accuracy of forecasts that serve as input data greatly affects the optimality of microgrid operation. The installed power of microgrid sources of electricity greatly contributes to the degree of self-sufficiency of the microgrid and the reduction of operating costs. The level of complexity (reality) of the battery energy storage system model enables the microgrid operator to manage different operation strategies as a compromise between reducing operating costs and extending equipment life.

Keywords: Microgrid, energy management system, short-term operation planning, renewable energy sources, battery energy storage system, optimization problem.

Životopis

Matej Žnidarec rođen je 24. veljače 1993. godine u Požegi. 2011. godine završava srednju Tehničku školu Požega, smjer tehničar za računalstvo te upisuje preddiplomski studij elektrotehnike, smjer elektroenergetika na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek. Diplomski studij elektrotehnike, smjer elektroenergetika upisuje 2014. godine kojeg završava u srpnju 2016. godine te stječe titulu magistar inženjer elektrotehnike, smjer elektroenergetika. Iste godine se zapošljava kao asistent na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek na Zavodu za elektroenergetiku i upisuje poslijediplomski doktorski studij elektrotehnike, smjer elektroenergetika. Tijekom 2017. godine Hrvatsko Energetsko Društvo zaklada „Hrvoje Požar“ dodjeljuje mu nagradu za posebno zapažen diplomski rad iz područja energetike, a 2018. godine dobiva priznanje Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek za iznadprosječne rezultate ostvarene kroz polaganje ispita i objavljivanje znanstvenih radova na poslijediplomskom doktorskom studiju elektrotehnike, smjer elektroenergetika.

Uže područje istraživanja su mu optimiranje pogona elektroenergetskog sustava i integracija obnovljivih izvora energije u elektroenergetski sustav. Objavio je veći broj znanstvenih radova u domaćim i međunarodnim časopisima te na konferencijama. Sudjeluje na više međunarodnih i domaćih projekata i održava nastavu iz pet kolegija na preddiplomskim i diplomskim studijskim programima iz područja elektrana, energetskih procesa i integracije obnovljivih izvora energije.