



**UNIVERZITET CRNE GORE
ELEKTROTEHNIČKI FAKULTET**

Maja Rolevski

**MODELOVANJE I PRAĆENJE TAČKE
MAKSIMALNE SNAGE FOTONAPONSKOG
PANELA PRIMJENOM NEURALNIH MREŽA**

– MAGISTARSKI RAD –

Podgorica, 2020. godine

INFORMACIJE O MAGISTRANTU

Ime i prezime:	Maja Rolevski
Datum i mjesto rođenja:	18.04.1995.godine, Podgorica, Crna Gora
Naziv završenog osnovnog studijskog programa i godina diplomiranja:	Energetika i automatika, 2017.
Naziv završenog specijalističkog studijskog programa i godina diplomiranja:	Energetika i automatika – Automatika, 2018.

INFORMACIJE O MAGISTARSKOM RADU

Naziv postdiplomskog magistarskog studijskog programa:	Automatika
Naslov rada:	Modelovanje i praćenje tačke maksimalne slike fotonaponskog panela primjenom neuralnih mreža
Fakultet:	Elektrotehnički fakultet, Univerzitet Crne Gore

OCJENA I ODBRANA MAGISTARSKOG RADA

Datum prijave magistarskog rada:	19.06.2019.
Datum sjednice Vijeća Univerzitetske jedinice na kojoj je prihvaćena tema:	25.10.2019.
Komisija za ocjenu teme i podobnosti magistranta:	Prof. dr Božo Krstajić Doc. dr Martin Ćalasan Doc. dr Žarko Zečević
Mentor:	Doc. dr Žarko Zečević
Komisija za ocjenu rada:	Prof. dr Božo Krstajić Doc. dr Martin Ćalasan Doc. dr Žarko Zečević
Komisija za odbranu rada:	Prof. dr Božo Krstajić Doc. dr Martin Ćalasan Doc. dr Žarko Zečević
Datum odbrane:	30.10.2020.

Predgovor

Određivanje što preciznijeg i jednostavnijeg modela fotonaponskog panela je predmet aktuelnih naučnih istraživanja, a od posebnog je značaja za optimalnu simulaciju, projektovanje i evaluaciju fotonaponskih sistema. Postoji više pristupa u modelovanju fotonaponskih panela. Najčešće se modelovanje panela vrši pomoću ekvivalentnih električnih kola, čiji se parametri određuju na osnovu podataka iz proizvodnih kataloga panela ili na osnovu eksperimentalno utvrđenih podataka. Pri tome, dostupni rezultati istraživanja pokazuju da ovi modeli nemaju visoku tačnost za sve vrijednosti iradijanse. Dodatno, oni mogu imati visoku računsku složenost koju uslovljava implicitan oblik strujno-naponskih jednačina modela, a koje je moguće riješiti jedino primjenom neke od iterativnih numeričkih metoda. S druge strane, modelovanje fotonaponskih panela se može izvršiti pomoću takozvanih soft-computing tehnika, pri čemu se najčešće koriste neuralne mreže. Modeli kreirani pomoću neuralnih mreža (NN modeli) pokazuju visoku tačnost za različite vrijednosti iradijanse, a uz to mogu biti veoma jednostavni, što predstavlja njihovu glavnu prednost u odnosu na ekvivalentna električna kola.

Kako bi fotonapski paneli bili podesni za primjene u realnom vremenu, pored visoke tačnosti, neophodno je da imaju i nisku računsku složenost. Opisani cilj je moguće ostvariti upotrebom neuralnih mreža. Upravo u ovom radu je pokazano da se primjenom neuralnih mreža sa jednim skrivenim slojem i malim brojem neurona u tom sloju može postići visoka tačnost u modelovanju strujno-naponske karakteristike fotonaponskog panela. Na ovaj način se dobija eksplicitna zavisnost izlaznih parametara (struje panela) od ulaznih parametara (napona, temperature i iradijanse), čime se značajno pojednostavljuje računska složenost modela. Osim toga, prednost NN modela jeste mogućnost treniranja kako na simuliranim (NN_s model), tako i na eksperimentalnim podacima (NN_e model). Strujno-naponske karakteristike NN_s modela i ekvivalentnog električnog kola se skoro u potpunosti poklapaju, dok, pri poređenju sa izmjerrenom (realnom) karakteristikom panela, NN_e model pokazuje bolje performanse u odnosu na NN_s model. Međutim, NN_e model zahtijeva veliki broj mjerjenih podataka, što može potencijalno predstavljati problem pri njegovom kreiranju.

Adekvatno definisan model panela je moguće primijeniti u sistemu za upravljanje solarnim panelima, tako da vrši: monitoring rada panela, predikciju proizvodnje električne energije, praćenje tačke maksimalne snage, itd. U ovom radu je razmatrana primjena algoritma za praćenje tačke maksimalne snage (eng. *Maximal Power Point Tracking – MPPT*) pri promjenljivim vremenskim uslovima. MPPT algoritmi se dijele na one koji nisu bazirani na modelu panela (model-free) i one koji zahtijevaju poznavanje modela (model-based). Model-free MPPT algoritmi vrše određivanje tačke maksimalne snage na osnovu mjerjenja napona i struje panela, bez poznavanja karakteristika samog panela. Njihovi osnovni nedostaci su mala brzina konvergencije, loše performanse pri naglim promjenama vremenskih uslova, oscilacije u stacionar-

nom stanju. S druge strane, model-based MPPT algoritmi koriste poznati model solarnog panela za definisanje tačke maksimalne snage. Ovi algoritmi prevazilaze navedene nedostatke model-free algoritama, pa samim tim pokazuju značajno bolje rezultate.

U ovom radu je dat predlog jednostavnog model-based MPPT algoritma zasnovanog na usvojenom NN modelu fotonaponskog panela, koji omogućava brzo praćenje tačke maksimalne snage i postizanje izrazito dobrih performansi, čak i u slučaju nagnih promjena atmosferskih uslova. Takođe, kako je za implementaciju ovog MPPT algoritma potrebno poznavanje solarne iradijanse, predložen je i algoritam za estimaciju iradijanse baziran na navedenom NN modelu, čime se izbjegava upotreba prilično skupih senzora.

Dakle, predložene metode omogućavaju postizanje optimalnog rada solarnog sistema pri različitim radnim uslovima. Uz to, one predstavljaju značajnu polaznu tačku za buduća istraživanja u ovoj oblasti.

Podgorica, avgust 2020. godine

Rezime

Fotonaponski paneli se najčešće modeluju ekvivalentnim električnim kolima, čiji se parametri određuju na osnovu nekoliko poznatih radnih tačaka u standardnim testnim uslovima iz proizvodnih kataloga panela ili na osnovu eksperimentalno utvrđenih podataka. Simulacija rada panela zahtijeva rješavanje stujno-naponske jednačine koja je implicitna po svojoj prirodi, primjenom Njutnove ili neke druge numeričke metode. U prvom dijelu ovog rada je izvršeno modelovanje strujno-naponske karakteristike fotonaponskog panela pomoću neuralne mreže (NN model). Pokazano je da se neuralnom mrežom može eksplicitno modelovati zavisnost struje panela od napona, temperature i iradijanse. Na osnovu rezultata simulacija se pokazuje da je moguće ostvariti veliku tačnost u modelovanju, čak i sa neuralnom mrežom koja se sastoji od jednog skrivenog sloja i malog broja neurona u tom sloju. Dakle, na ovaj način se pojednostavljuje računska složenost modela, što je naročito značajno u real-time primjenama, kao što su praćenje tačke maksimalne snage, monitoring rada panela, predikcija proizvodnje električne energije.

Drugi dio rada se odnosi upravo na primjenu razvijenog NN modela u praćenju tačke maksimalne snage. Naime, fotonaponski paneli zahtijevaju upotrebu algoritma za praćenje tačke maksimalne snage (MPPT algoritmi) sa ciljem maksimizacije generisane snage panela u svakom trenutku. U ovom radu je predložen MPPT algoritam jednostavne strukture koji je baziran na NN modelu panela. Konkretno, izraz za izlaznu struju NN modela se koristi za izvođenje analitičkih, iterativnih pravila za određivanje napona u tački maksimalne snage, kao i za estimaciju solarne iradijanse. Na ovaj način, računska kompleksnost je značajno smanjena u poređenju sa ostalim MPPT metodama baziranim na neuralnim mrežama, u kojima se optimalni napon određuje direktno iz mjerjenja. Predloženi MPPT algoritam nema mogućnost trenutnog određivanja optimalnog napona, ali on sadrži parametar čijim se podešavanjem može postići željeni kompromis između brzine praćenja tačke maksimalne snage i računske kompleksnosti. Numerički rezultati pokazuju da relativna greška između stvarne maksimalne snage i maksimalne snage predviđene predloženim algoritmom može imati značajno manju vrijednost u odnosu na druge algoritme predložene u literaturi.

Ključne riječi: Fotonaponski panel – PV panel – Neuralna mreža – Modelovanje – MPPT algoritam

Abstract

Photovoltaic (PV) panels are usually modeled with equivalent electric circuits, whose parameters are determined on the basis of several known operating points in Standard Test Conditions from the photovoltaic catalogue or based on experimentally determined data. Simulation of the solar panel requires solving a current-voltage equation which is implicit in its nature, by using Newton's or some other numerical method. In the first part of this paper, the photovoltaic current-voltage characteristics are modeled by using a neural network (NN model). It has been shown that the neural network can explicitly model the dependence of the photovoltaic current on voltage, temperature and irradiance. Simulation results show that it is possible to achieve high accuracy in modeling, even with the neural network consisting of one hidden layer and a small number of neurons in that layer. In this way, the computational complexity of the model is simplified, which is especially significant in real-time applications, such as maximum power point tracking, panel monitoring, electricity generation prediction.

The second part of this paper is mainly focused on the application of developed NN model for photovoltaic maximum power point tracking (MPPT). Namely, PV panels require MPPT algorithms to ensure that the amount of power extracted is maximized. In this paper, a low-complexity MPPT algorithm based on the NN model is proposed. Precisely, the expression for the output current of the NN model is used to derive the analytical, iterative rules for determining the maximal power point (MPP) voltage and irradiance estimation. In this way, the computational complexity is reduced compared to the other NN-based MPPT methods, in which the optimal voltage is predicted directly from the measurements. The proposed algorithm cannot instantaneously determine the optimal voltage, but it contains a tunable parameter for controlling the trade-off between the tracking speed and computational complexity. Numerical results indicate that the relative error between the actual maximum power and the one obtained by the proposed algorithm can be up to ten times smaller than in the available algorithms.

Key words: Photovoltaic panel – PV panel – Neural network – ANN – Modeling – Model-based MPPT control

Sadržaj

Predgovor	i
Rezime	iii
Abstract	iv
Lista skraćenica	vii
Lista slika	ix
Lista tabela	xi
Uvod	1
1 Modelovanje fotonaponskih panela	4
1.1 Osobine solarne čelije	4
1.1.1 P-N spoj	4
1.1.2 Struktura solarne čelije	9
1.2 Jednodiodni model solarne čelije	9
1.2.1 Jednodiodni idealni model solarne čelije	10
1.2.2 Jednodiodni model solarne čelije sa paralelnom otpornošću . .	12
1.2.3 Jednodiodni model solarne čelije sa serijskom otpornošću . .	13
1.2.4 Kompletan jednodiodni model solarne čelije	14
1.2.5 Definicija solarne čelije, modula i panela. Jednodiodni model solarnog panela	17
1.3 Dvodiодni model solarne čelije	20
1.4 Modifikovani jednodiodni model solarne čelije	22
1.4.1 Eksplizitni oblik modela čelije	23
1.4.2 Eksplizitni oblik modela panela	24
1.5 Model efikasnosti solarne čelije	26
2 Algoritmi za praćenje tačke maksimalne snage	29
2.1 Faktor popunjenošt. Efikasnost fotonaponske čelije	29
2.2 Uticaj solarne iradijanse i temperature	30
2.3 Formulacija i implementacija MPPT algoritma	32
2.4 Algoritam pomjeraja i posmatranja (eng. <i>Perturb and Observe – P&O</i>)	34
2.4.1 P&O algoritam sa varijabilnim perturbacionim korakom . . .	36
2.5 Algoritam inkrementalne konduktanse (eng. <i>Incremental Conductance – IC</i>)	38

2.6	Model-based MPPT algoritam baziran na ekvivalentnom električnom kolu panela	40
2.6.1	Slučaj poznate solarne iradijanse	40
2.6.2	Slučaj nepoznate solarne iradijanse	41
3	MPPT algoritmi zasnovani na neuralnim mrežama	42
3.1	Arhitektura i princip rada neuralne mreže	42
3.2	Modelovanje fotonaponskog panela pomoću neuralne mreže	44
3.3	Pregled MPPT algoritama baziranih na neuralnim mrežama	46
3.4	Predlog MPPT algoritma i estimatora iradijanse baziranih na NN modelu panela	47
3.4.1	NMPPT algoritam	48
3.4.2	Estimacija solarne iradijanse	49
3.4.3	Računska kompleksnost predloženog rješenja	50
4	Rezultati simulacija	51
4.1	Komparativna analiza predloženog modela neuralne mreže sa modelom mreže drugačije arhitekture	51
4.1.1	NN model: jedan skriveni sloj, tri neurona	52
4.1.2	NN model: dva skrivena sloja, četiri-tri neurona	54
4.1.3	Poređenje performansi NN_3 i NN_{43} modela	55
4.2	Komparativna analiza predloženog NMPPT algoritma sa drugim MPPT algoritmima	57
4.2.1	Primjena simuliranih podataka	57
4.2.2	Primjena eksperimentalnih podataka	61
Zaključak		65
Bibliografija		66
Prilog		76

Lista skraćenica

AM	relativna masa vazduha (eng. <i>Air Mass</i>)
AC	naizmjenična struja (eng. <i>Alternating Current</i>)
ANFIS	adaptivni neuro-fazi sistemi (eng. <i>Adaptive Neuro-Fuzzy Systems</i>)
CNNMPPT	MPPT algoritam baziran na kaskadnim neuralnim mrežama (eng. <i>Cascade Neural Network MPPT</i>)
CNNEST	estimator iradijanse koji se primjenjuje uz CNNMPPT algoritam
DC	jednosmjerna struja (eng. <i>Direct Current</i>)
EMPPT	model-based MPPT algoritam baziran na jednodiodnom ekivalentnom električnom kolu panela
EP	razlika između maksimalne snage simuliranog panela i maksimalne snage predviđene NN modelom
EEST	estimator iradijanse koji se primjenjuje uz EMPPT algoritam
IC	metoda inkrementalne konduktanse (eng. <i>Incremental Conductance</i>)
MPPT	algoritam za praćenje tačke maksimalne snage (eng. <i>Maximal Power Point Tracking</i>)
MPP	tačka maksimalne snage (eng. <i>Maximal Power Point</i>)
MSE	srednja kvadratna greška (eng. <i>Mean Squared Error</i>)
MSEI	srednja kvadratna razlika između struje simuliranog panela i struje predviđene NN modelom
MSEP	srednja kvadratna razlika između snage simuliranog panela i snage predviđene NN modelom
NN	neuralna mreža (eng. <i>Neural Network</i>)
NN model	model baziran na neuralnoj mreži (eng. <i>Neural Network model</i>)
NI&I estimator	estimator iradijanse baziran na principu imerzije i invarijanse (eng. <i>Neural Immersion & Invariance</i>)
NGE	neuralni gradijentni estimator iradijanse (eng. <i>Neural Gradient Estimator</i>)
NMPPT	predloženi MPPT algoritam baziran na modelu neuralne mreže
NN₃	model neuralne mreže sa jednim skrivenim slojem koji se sastoji od tri skrivena neurona
NN₄₃	model neuralne mreže sa dva skrivena sloja u kojima se nalaze četiri i tri skrivena neurona, respektivno
NREL	Nacionalna laboratorija obnovljivih izvora energije (eng. <i>National Renewable Energy Laboratory</i>)
NN_s	NN model treniran pomoću simuliranih podataka
NN_e	NN model treniran pomoću eksperimentalnih podataka
NNMPPT_s	NNMPPT algoritam baziran na simuliranim podacima
NNMPPT_e	NNMPPT algoritam baziran na eksperimentalnim podacima

NI&I_s	NI&I estimator baziran na simuliranim podacima
NI&I_e	NI&I estimator baziran na eksperimentalnim podacima
PV	fotonaponski (eng. <i>photovoltaic</i>)
PI kontroler	proporcionalno-integralni kontroler
PWM	impulsno-širinska modulacija (eng. <i>Pulse Width Modulation</i>)
P&O	metoda pomjeraja i posmatranja (eng. <i>Perturb and Observe</i>)
STC	standardni uslovi za testiranje (eng. <i>Standard Test Conditions</i>)

Lista slika

1.1	Grafički prikaz atoma silicijuma	4
1.2	Grafički prikaz kovalentne veze silicijuma sa četiri susjedna atoma	5
1.3	Grafički prikaz formiranja šupljine i rekombinacije	5
1.4	Grafički prikaz kretanja šupljine	6
1.5	N tip materijala	7
1.6	P tip materijala	7
1.7	P-N spoj	8
1.8	Dioda kao poluprovodnički element	8
1.9	Prikaz fotonaponskog efekta	9
1.10	Jednodiodni idealni model solarne čelije	10
1.11	Značajni parametri solarne čelije	11
1.12	$I-V$ karakteristika solarne čelije	11
1.13	Jednostavno kolo serijski povezanih solarnih čelija	12
1.14	Jednodiodni model solarne čelije sa paralelnom otpornošću	13
1.15	$I-V$ karakteristika solarne čelije sa dodatom paralelnom otpornošću	13
1.16	Jednodiodni model solarne čelije sa serijskom otpornošću	14
1.17	$I-V$ karakteristika solarne čelije sa dodatom serijskom otpornošću	14
1.18	Jednodiodni model solarne čelije sa paralelnom i serijskom otpornošću	15
1.19	$I-V$ karakteristika solarne čelije sa dodatom paralelnom i serijskom otpornošću	16
1.20	Solarna čelija, modul i panel	18
1.21	Povećanje izlaznog napona uslijed serijski povezanih modula	18
1.22	Povećanje izlazne struje uslijed paralelno povezanih modula	19
1.23	Povezivanje modula u panel	20
1.24	Dvodiodni model solarne čelije	21
1.25	Unaprijeđeni jednodiodni model solarne čelije	22
1.26	$I-V$ karakteristika unaprijeđenog jednodiodnog modela solarne čelije	23
1.27	$I-V$ karakteristika niza serijski povezanih čelija, sa i bez bypass diode	25
1.28	Metod za predikciju dnevne, mjesecne i godišnje proizvedene energije, kao i specifične cijene njene proizvodnje	28
2.1	Značajne tačke $I-V$ i $P-V$ karakteristike solarne čelije	30
2.2	$I-V$ i $P-V$ karakteristike za različite vrijednosti solarne iradijanse i temperature	32
2.3	Prikaz fotonaponskog sistema	33
2.4	Šema Boost copera	33
2.5	Primjer klizanja radne tačke	35
2.6	Šematski prikaz P&O algoritma	36
2.7	Šematski prikaz P&O algoritma sa varijabilnim perturbacionim korakom napona	37

2.8	Prikaz uslova algoritma inkrementalne konduktanse na P - V krivoj	38
2.9	Šematski prikaz algoritma inkrementalne konduktanse	39
3.1	Feedforward neuralna mreža sa jednim skrivenim slojem	44
3.2	Arhitektura NN modela fotonaponskog panela	45
3.3	Arhitektura neuralnih mreža korištenih za estimaciju V_{mpp} i G	47
4.1	Komparacija karakteristika simuliranog ekvivalentnog kola panela i NN_3 modela neuralne mreže	53
4.2	Komparacija karakteristika simuliranog ekvivalentnog kola panela i NN_{43} modela neuralne mreže	55
4.3	Komparacija P - V karakteristika panela generisanih od strane ekvivalentnog kola i NN modela panela	58
4.4	Performansa predloženog algoritma za različite vrijednosti P	59
4.5	Komparacija algoritama pri nagloj promjeni solarne iradijanse i temperature	59
4.6	Komparacija algoritama pri linearnoj promjeni solarne iradijanse i temperature	60
4.7	Eksperimentalni podaci korišteni za treniranje NN_e modela, odnosno NMPPT _e algoritma i NI&I _e estimatora iradijanse	61
4.8	Komparacija mjerenih P - V karakteristika i P - V karakteristika NN_s/NN_e modela	62
4.9	Komparacija algoritama pri nagloj promjeni solarne iradijanse i temperature	62
4.10	Komparacija algoritama pri različitim varijacijama solarne iradijanse u vremenu	63
4.11	Komparacija algoritama pri različitim varijacijama solarne iradijanse u vremenu	64

Lista tabela

2.1	Tabelarni prikaz P&O algoritma	35
4.1	Karakteristike solarne čelije	51
4.2	Pregled vrijednosti grešaka NN modela, pri promjeni temperature . .	56
4.3	Pregled vrijednosti grešaka NN modela, pri promjeni solarne iradijanse	56
4.4	Prikaz relativnih grešaka između predviđene i stvarne vrijednosti maksimalne snage	61
4.5	Prikaz relativnih grešaka između predviđene i stvarne vrijednosti maksimalne snage	64

Uvod

Izvori električne energije se u globalu mogu podijeliti na konvencionalne, odnosno neobnovljive, i obnovljive izvore energije. Pri tome, u grupu konvencionalnih izvora spadaju ugalj, gas, nafta, nuklearna goriva, čije se zalihe vremenom iscrpljuju, dok njihova cijena na tržištu raste. Osim toga, jedan od glavnih nedostataka ovih izvora jeste otpuštanje štetnih gasova u atmosferu, što značajno doprinosi klimatskim promjenama i globalnom zagrijavanju [1]. S druge strane, obnovljivi izvori energije su zbog svojih brojnih prednosti sve više u upotrebi. Solarna energija, energija vjetra i baterijski sistemi za skladištenje energije se smatraju najznačajnijim rješenjima kada je riječ o "čistoj" energiji. Iz tog razloga, Internacionalna energetska agencija (eng. *International Energy Agency*) ih je svrstala u jedine tehnologije čiji brz razvoj može uticati na usporenje daljih klimatskih promjena [2]. Energija generisana od strane solarnih i vjeroelektrana danas ima mnogo manju cijenu od energije dobijene pomoću fosilnih goriva. Pri tome, cijena baterijskih sistema dodatno opada zbog čega se oni sve više koriste za skladištenje energije, što je od ključnog značaja za upotrebu obnovljivih izvora.

Fotonaponski paneli se dominantno izgrađuju od kristalnog silicijuma, zbog čega se ostali materijali više gotovo ne primjenjuju u njihovoj proizvodnji. Kao rezultat toga, 2016. godine, silicijumski paneli su generisali 94% globalne solarne energije. Tokom posljednje decenije, cijena silicijumskih panela je opala za preko 90%, a solarna energija se u mnogim regijama smatra najjeftinijim izvorom energije. Iz tog razloga, upotreba solarne energije je doživjela nagli porast u poređenju sa ostalim izvorima.

Međutim, učešće solarne energije u globalnoj proizvodnji električne energije bi trebalo da poraste sa današnjih 2% udjela na 33% do sredine ovog vijeka, kako bi se izvršila potpuna dekarbonizacija elektroenergetskog sektora [3, 4]. S tim ciljem, bitno je vršiti stalno unapređenje postojećih solarnih sistema, bilo da je riječ o njihovoj konstrukciji, održivosti pada cijene, maksimizacije efikasnosti, i sl. Kada je riječ o efikasnosti solarnog sistema, može se reći da na nju primarno utiču sljedeći faktori: efikasnost solarnih čelija (između 20 i 25% [5]), efikasnost energetskog pretvarača (veća od 95% [6]), te efikasnost metode za praćenje tačke maksimalne snage (čak i do 98-99% [7]). Pri tome, povećanje efikasnosti solarnih čelija i pretvarača zahtijeva bolje i skuplje tehnologije, zbog čega implementacija navedene metode za praćenje tačke maksimalne snage ima najveći značaj.

Naime, solarni paneli imaju nelinearnu konkavnu P - V karakteristiku, sa tačno jednom tačkom maksimuma snage (eng. *Maximum Power Point* – MPP). Ova tačka zavisi od atmosferskih uslova, odnosno solarne iradijanse i temperature, čije vrijednosti značajno variraju na dnevnom, mjesecnom, odnosno godišnjem nivou. Iz

tog razloga, veoma je važno pratiti tačku MPP pri svim uslovima, tako da se u svakom trenutku omogući generisanje maksimalne moguće snage. Upravo to se postiže primjenom metode za praćenje tačke maksimalne snage (eng. *Maximum Power Point Tracking* – MPPT) koja se implementira u energetskom pretvaraču solarnog sistema, a funkcioniše po principu prepodešavanja vrijednosti faktora popunjenoštij pretvarača.

U posljednjem periodu, mnogobrojni MPPT algoritmi su predloženi u literaturi [8, 9]. Oni se međusobno razlikuju po svojoj kompleksnosti, cijeni, efikasnosti, te se u skladu sa tim mogu klasifikovati na različite načine. U ovom radu je usvojena podjela MPPT algoritama na one koji nisu zasnovani na modelu panela (model-free) i one koji zahtijevaju poznavanje modela panela (model-based). Pri tome, model-free algoritmi, iako jeftine implementacije, pokazuju malu brzinu konvergencije i loše performanse pri naglim promjenama vremenskih uslova. S druge strane, model-based metode se karakterišu brzim odzivom na česte promjene vremenskih uslova i visokom efikasnošću u stacionarnom stanju. Ipak, one zahtijevaju upotrebu senzora za iradijansu koji su skupi, ali taj problem može biti prevaziđen upotrebom algoritma za estimaciju iradijanse. Danas su upotrebi različiti pristupi za kreiranje modela panela, među kojima se izdvajaju jednodiodno električno ekvivalentno kolo panela i soft-computing tehnike (neuralne mreže, fazi logika, itd.). Jednodiodno ekvivalentno kolo je prilično jednostavne strukture, a obezbjeđuje i zadovoljavajuću tačnost. Sadrži pet nepoznatih parametara koji se estimiraju na osnovu informacija obezbijeđenih od strane proizvođača ili na osnovu eksperimentalno dobijenih podataka [10]. Međutim, strujno-naponske jednačine ovog modela panela su zadate u implicitnom obliku, pa je za njihovo rješavanje potrebno upotrijebiti iterativnu Njutn-Rapsonovu metodu [11]. Da bi se izbjeglo iterativno rješavanje jednačina i time smanjila računska kompleksnost, najčešće se pribjegava upotrebi soft-computing tehnika.

U ovom radu je izvršeno modelovanje strujno-naponske karakteristike solarnog panela pomoću neuralne mreže (NN model), sa ciljem razvoja jednostavnog modela visoke tačnosti, a pri tom niske računske kompleksnosti. Predloženi model neuralne mreže zadovoljava sve navedene kriterijume, pri čemu je niska računska kompleksnost ostvarena postizanjem eksplisitne zavisnosti između izlazne struje i izlaznog napona panela. Tako definisan NN model je primijenjen u razvoju predloženog građijentnog MPPT algoritma, znatno niže računske kompleksnosti u odnosu na ostale MPPT algoritme bazirane na neuralnim mrežama. Osim toga, ovaj MPPT algoritam omogućava brzo praćenje tačke maksimalne snage i visoku tačnost u stacionarnom stanju, bez pojave oscilacija. Takođe, predložen je estimator solarne iradijanse, koji se oslanja na predloženi NN model.

Magistarski rad se sastoji od uvoda, četiri poglavља, zaključka, liste referenci i priloga. U prvom poglavljiju su, najprije, predstavljene opšte karakteristike, princip funkcionisanja i struktura solarne ćelije kao osnovne jedinice solarnog panela. Takođe, dat je opis najčešće korišćenih ekvivalentnih električnih kola za modelovanje solarnog panela. U drugom poglavljju je uveden problem praćenja tačke maksimalne snage, a zatim su opisani i klasifikovani najčešće korišćeni MPPT algoritmi, sa osvrtom na njihove prednosti i mane. Pri tome, dat je opis značajnih model-free MPPT algoritama, kao i model-based MPPT algoritma koji se bazira na ekvivalentnom

električnom kolu panela. Treće poglavje govori o model-based MPPT algoritmima koji su razvijeni pomoću neuralnih mreža. Konkretno, nakon kraćeg uvoda u neuralne mreže, opisan je postupak modelovanja solarnih panela upotrebom neuralnih mreža. Zatim je dat predlog MPPT algoritma i algoritma za estimaciju iradijanse koji se zasnivaju na definisanom NN modelu. U četvrtom poglavju su prezentovani rezultati simulacija. Pri tom, izvršena je komparacija različitih arhitektura neuralnih mreža za modelovanje fotonaponskih panela, kao i komparacija predloženog i konvencionalnih algoritama za praćenje tačke maksimalne snage, u kombinaciji sa odgovarajućim estimatorima iradijanse. U zaključku rada su diskutovani rezultati magistarske teze, odnosno doprinosi u odnosu na dosadašnja istraživanja. Konačno, u prilogu rada je predstavljen programski kod realizovan u Matlab-u r2017a, pomoću kojeg su izvršene opisane simulacije.

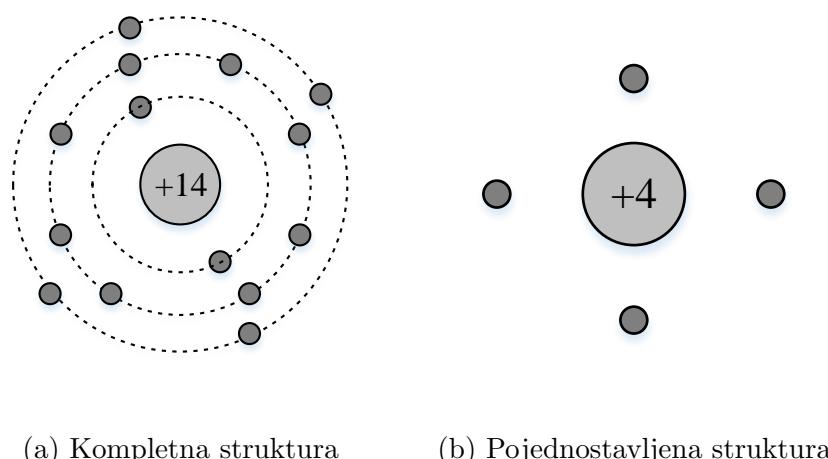
Glava 1

Modelovanje fotonaponskih panela

1.1 Osobine solarne čelije

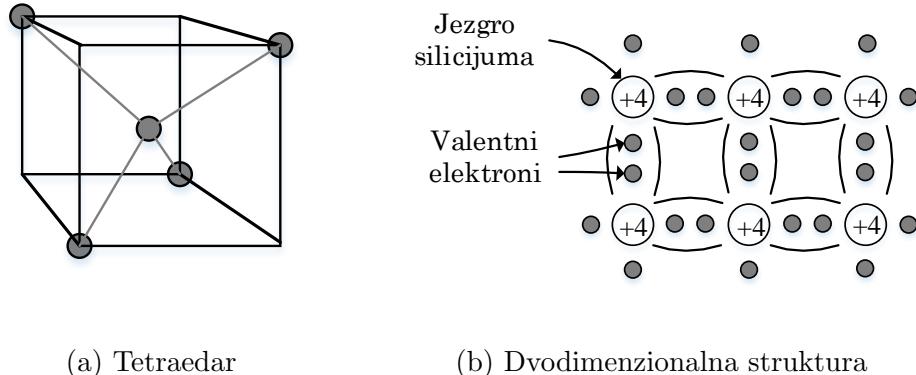
1.1.1 P-N spoj

Solarne čelije se proizvode na bazi materijala poluprovodničke prirode, zahvaljujući čemu je omogućena konverzija solarne energije u električnu energiju. U tu svrhu, najčešće upotrebljivan materijal jeste čisti kristalni silicijum koji pripada IV grupi Periodnog sistema. Germanijum je, takođe, element iz IV grupe koji se često koristi. S druge strane, elementi koji se uglavnom dodaju silicijumu jesu bor (III grupa) i fosfor (V grupa). Silicijum ima 14 protona u svom jezgru i 14 elektrona na svojim orbitama, pri čemu njegova spoljašnja orbita sadrži 4 valentna elektrona (slika 1.1a). Kako su ti valentni elektroni od presudnog značaja u elektronici, atom silicijuma se najčešće predstavlja slikom 1.1b, sa 4 protona u svom jezgru i 4 valentna elektrona.



Slika 1.1: Grafički prikaz atoma silicijuma [12]

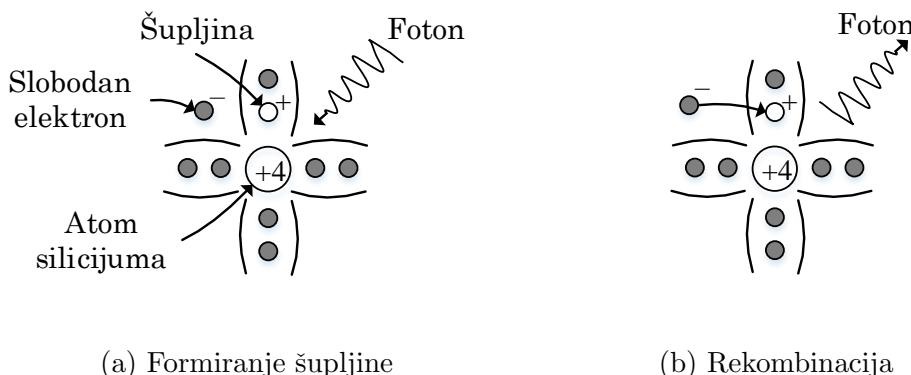
Čisti atom kristalnog silicijuma gradi kovalentne veze sa 4 susjedna atoma, formirajući pri tom trodimenzionalni tetraedar (slika 1.2a), koji se češće prikazuje dvo-dimenzionalnom strukturu predstavljenom na slici 1.2b.



Slika 1.2: Grafički prikaz kovalentne veze silicijuma sa četiri susjedna atoma

Pri nultoj temperaturi, silicijum predstavlja električni izolator. Međutim, povećanje temperature omogućava elektronima da prikupe dovoljnu količinu energije, tako da mogu da napuste svoje atome i počnu da se kreću u vidu električne struje. Dodatnim zagrijavanjem se oslobađa još više elektrona – provodljivost poluprovodnika se povećava sa povećanjem temperature. Kako je provodljivost silicijuma pri normalnim temperaturama prilično mala, najčešće mu se dodaju primjese drugih materijala čime se postiže veća provodljivost.

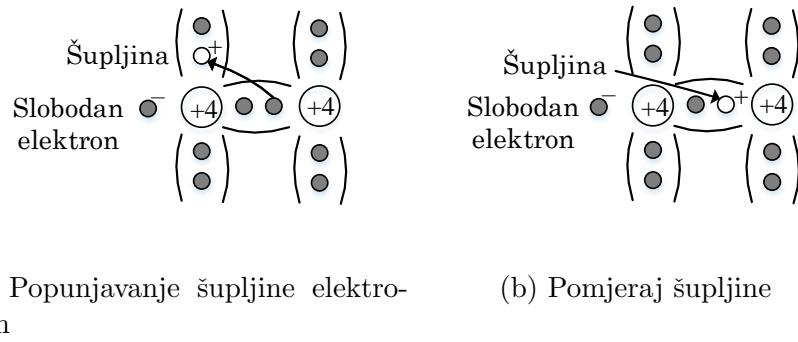
Energija koju elektron mora da dobije kako bi se oslobođio elektrostatičke sile koja ga vezuje za jezgro atoma, se naziva band-gap energija. Ona ima određenu vrijednost za svaki materijal, a za silicijum iznosi 1.12 eV. Za solarne ćelije, izvor ove energije predstavljaju nosioci elektromagnetne energije sunca – fotoni. Kada solarna ćelija absorbuje foton energije veće od 1.12 eV, jedan elektron napušta svoj atom silicijuma, ostavljajući jezgru sa 4 protona i samo 3 valentna elektrona. Mjesto koje ostaje upražnjeno odlaskom tog elektrona se smatra pozitivnim nanelektrisanjem i naziva se šupljina (slika 1.3a). Nakon toga će se izvršiti proces rekombinacije, kada neki elektron zauzima mjesto šupljine, oslobađajući pri tom energiju fotona koju je nosio sa sobom (slika 1.3b).



Slika 1.3: Grafički prikaz formiranja šupljine i rekombinacije

Važno je navesti da se, osim elektrona, takođe "kreću" i šupljine kao nosioci pozitivnog nanelektrisanja. Naime, kada se šupljina ispunji nekim susjednim valentnim

elektronom, tada se ona premješta na atom odakle potiče taj elektron, što je predstavljeno slikom 1.4. Na taj način se kreiraju parovi elektron-šupljina. Pri tome, kretanje šupljina, jednako kao kretanje elektrona, uzrokuje pojavu električne struje u poluprovodniku [13].



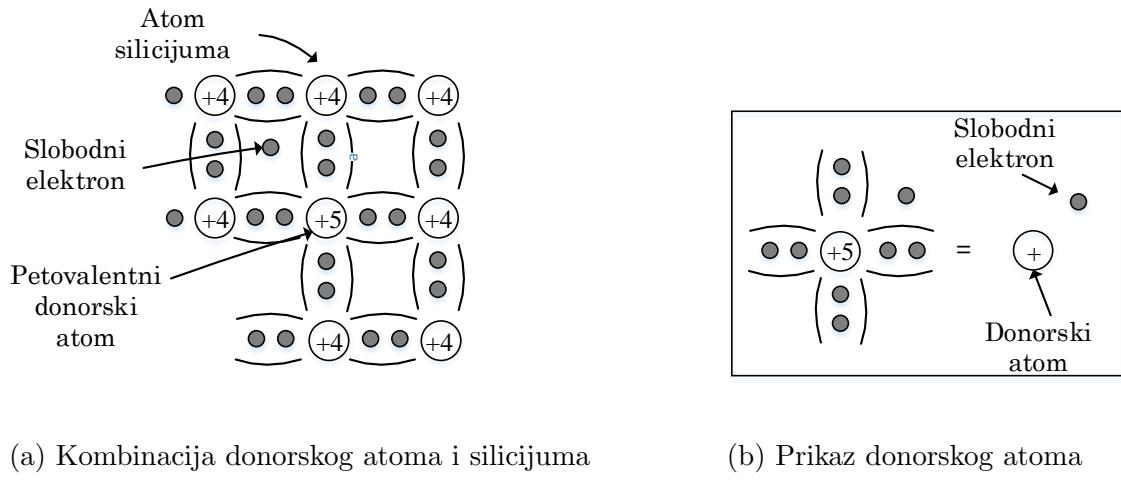
Slika 1.4: Grafički prikaz kretanja šupljine

Dakle, dokle god je solarna ćelija izložena energiji fotona većoj od band-gap energije, parovi elektron-šupljina će se formirati. Problem se može pojaviti kada se elektroni, nakon napuštanja svog mesta u atomu, vrate nazad na isto mjesto, uzrokujući pri tom nestanak oba nosioca nanelektrisanja. Ovaj vid rekombinacije se može izbjegći stalnim udaljavanjem elektrona, koji su napojeni energijom, od svojih šupljina. U solarnim ćelijama se to postiže formiranjem električnog polja u samom poluprovodniku, koje usmjerava elektrone u jednom smjeru, a šupljine u drugom. S tim ciljem, kreiraju se dvije regije: u jednoj regiji se silicijumu dodaje malo primjesa trovalentnog elementa iz III grupe Periodnog sistema, dok mu se u drugoj regiji dodaju petovalentni atomi elementa iz V grupe.

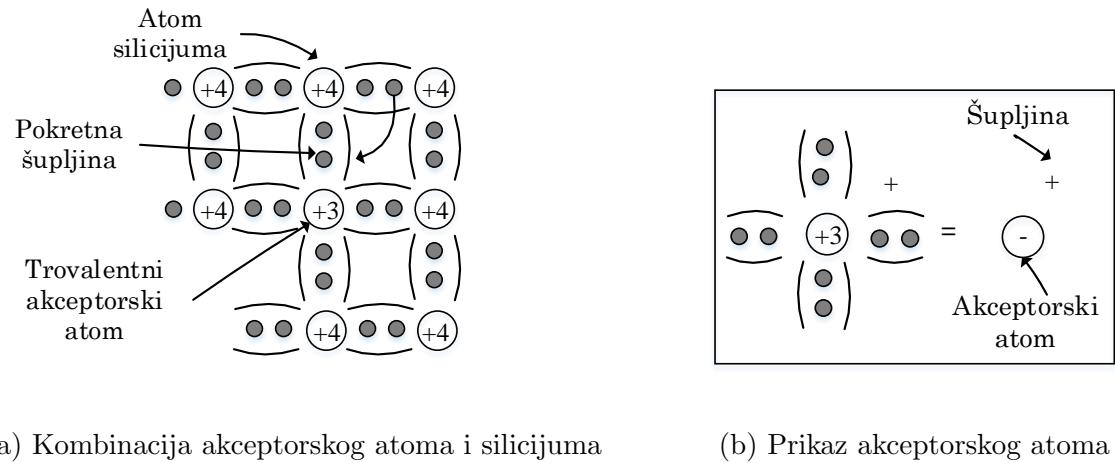
Posmatrajmo stranu poluprovodnika gdje je dodat petovalentni element, npr. fosfor. Tada, atom petovalentnog elementa formira četiri kovalentne veze sa četiri susjedna silicijumova atoma (slika 1.5), pri čemu njegov jedan elektron ostaje slobodan da se kreće po kristalu. Kada taj elektron napusti svoj donorski atom, ostaće $+5$ donorski jon okružen sa 4 negativna valentna elektrona. Iz tog razloga, svaki donorski atom se može predstaviti kao jedno fiksno pozitivno nanelektrisanje sa slobodnim elektronom u svojoj okolini (slika 1.5b). Petovalentni, $+5$ elementi, doniraju elektrone svojem dijelu poluprovodnika, zbog čega se nazivaju donori. Kako sada postoje negativna nanelektrisanja koja se mogu kretati po kristalu, poluprovodnik kojem se doda donorski atom se naziva materijal N tipa.

S druge strane poluprovodnika, silicijumu se dodaje trovalentni element, kao npr. bor, čiji atomi formiraju kovalentne veze sa susjednim atomima silicijuma, što je prikazano slikom 1.6. Kako trovalentni element ima tri valentna elektrona, formiraju se samo tri kovalentne veze, što uslovjava pojavu pozitivno nanelektrisane šupljine pored njegovog atoma. Tada elektron iz susjednog atoma silicijuma prelazi u tu šupljinu, zbog čega se atom trovalentnog elementa naziva akceptor. Ispunjena šupljina sada znači da 4 negativna nanelektrisanja okružuju $+3$ jezgro. Sve 4 kovalentne veze su sada popunjene, formirajući pri tom fiksnu negativno nanelektrisanu strukturu u svakom akceptorskom atomu. Uz to, svaki akceptor je kreirao pozitivno

naelektrisanu šupljinu koja se može slobodno kretati po kristalu, zbog čega se ova strana poluprovodnika naziva materijal P tipa.

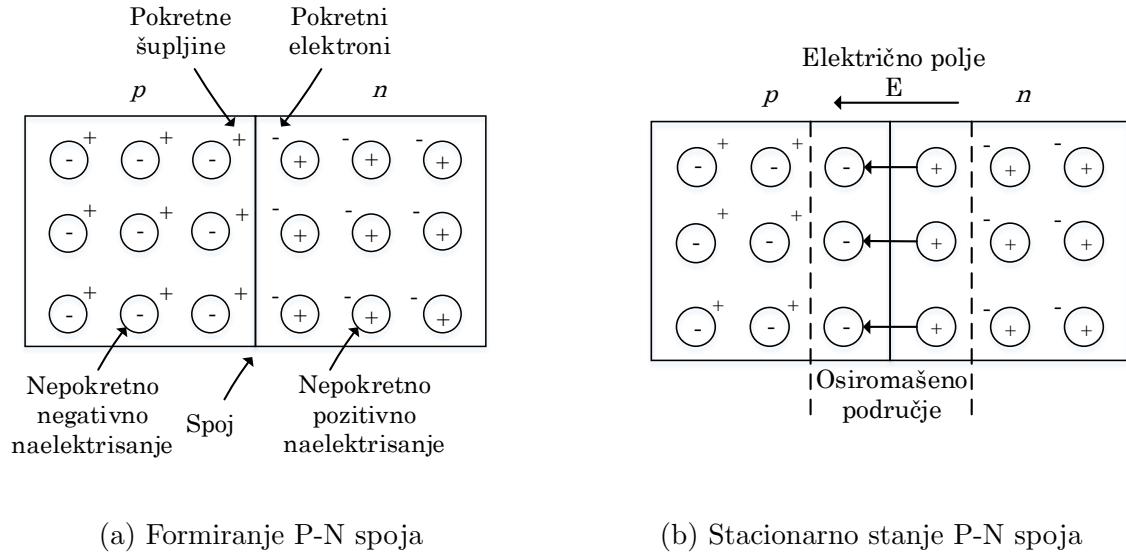


Slika 1.5: N tip materijala [12]



Slika 1.6: P tip materijala [12]

Ukoliko se formira spoj opisanog P i N tipa materijala, doći će do preraspodjele slobodnih nosilaca nanelektrisanja u njima. Konkretno, pokretni elektroni iz N dijela prelaze u P dio, dok pokretne šupljine iz P dijela odlaze u suprotnom smjeru, prema N dijelu. Kada elektron uđe u P dio, on popunjava šupljinu, ostavljajući nepokretno pozitivno nanelektrisanje u N dijelu, a pri tom formirajući nepokretno negativno nanelektrisanje u P dijelu (slika 1.7a). Ovako nepokretna nanelektrisanja u P i N regija formiraju električno polje koje se neko vrijeme suprotstavlja kretanju pokretnih elektrona i šupljina preko spoja, nakon čega će izazvati njihovo zaustavljanje. Nepokretna nanelektrisanja koja kreiraju električno polje u blizini spoja, formiraju tzv. osiromašeno područje, zbog toga što su iz ove regije pokretna nanelektrisanja nestala (slika 1.7b) [13].

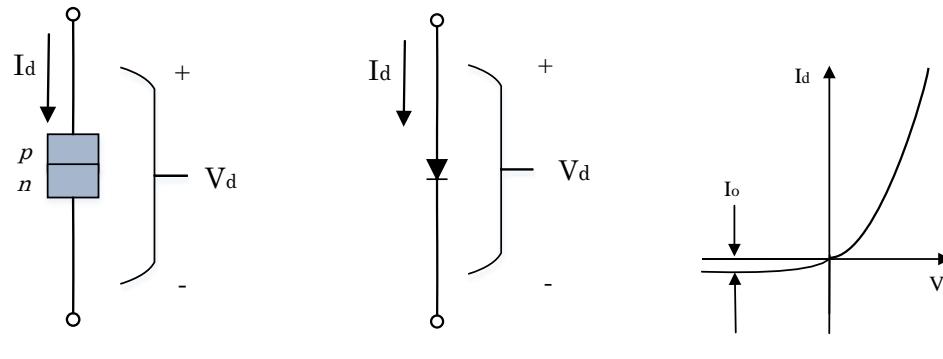


Slika 1.7: P-N spoj [12]

Prethodno opisani princip funkcionisanja P-N spoja, direktno karakteriše rad diode, koja sama po sebi i predstavlja P-N spoj (slika 1.8). Ako se krajevi diode priključe na napon V_d tako da pozitivan potencijal odgovara anodi, a negativan katodi, dioda će postati direktno polarizovana, pa će struja I_d proteći kroz nju od P ka N dijelu. Ako se, ipak, na krajeve diode dovede suprotan napon, tada će ona postati inverzno polarisana i propustiće malu struju zasićenja I_s . $I-V$ karakteristika diode prikazana slikom 1.8c, se definije pomoću jednačine:

$$I_d = I_s \left[\exp\left(\frac{qV_d}{nkT}\right) - 1 \right], \quad (1.1)$$

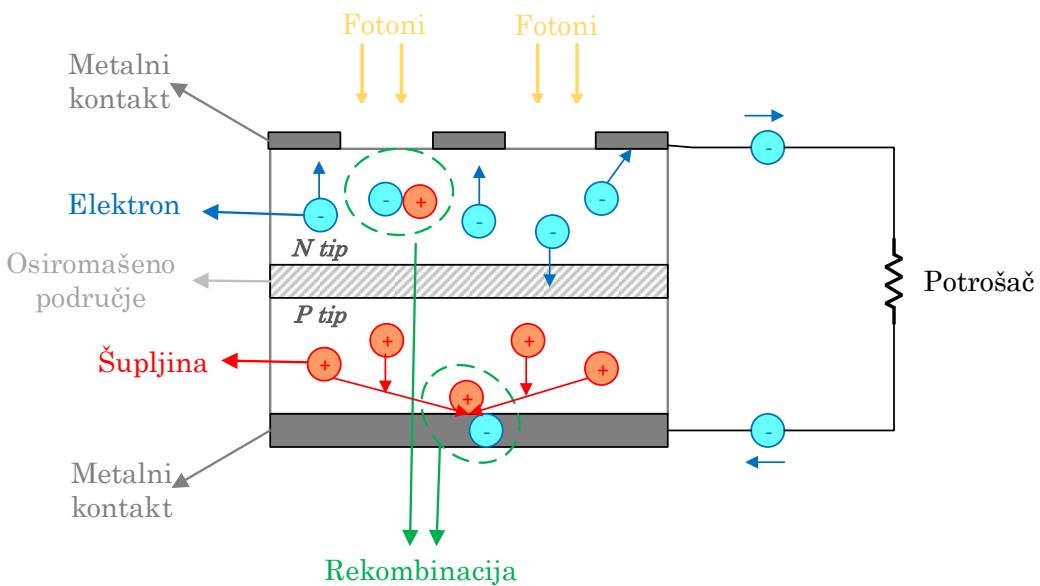
gdje je I_s struja zasićenja diode [A], q količina elementarnog nanelektrisanja [= 1.602×10^{-19} C], V_d napon na diodi [V], n faktor kvaliteta diode, k Boltzmanova konstanta [= 1.381×10^{-23} J/K], a T termodinamička temperatura [K] [13, 14, 15].



Slika 1.8: Dioda kao poluprovodnički element [12]

1.1.2 Struktura solarne ćelije

Posmatrajmo sada P-N spoj u slučaju solarne ćelije. Kada se solarna ćelija izloži sunčevom zračenju, ona absorbuje fotone, što uslovjava formiranje parova elektron-šupljina. Ako se ovi pokretni nosioci nanelektrisanja približe spoju, električno polje u osiromašenom području će usmjeriti šupljine ka P dijelu, a elektrone ka N dijelu. U P regiji se akumuliraju šupljine, a u N regiji elektroni, te se na taj način formira napon. Ukoliko se električni kontakti priključe za gornji i donji dio ćelije, elektroni će se kretati od N dijela kroz opterećenje, pa nazad do P dijela. Kada dođu do P dijela, elektroni se rekombinuju sa šupljinama, zatvarajući pri tom krug. Po konvenciji, pozitivna struja ima smjer suprotan kretanju elektrona. Opisani proces se naziva fotonaponski efekat, a prikazan je na slici 1.9 [16, 17].



Slika 1.9: Prikaz fotonaponskog efekta [12]

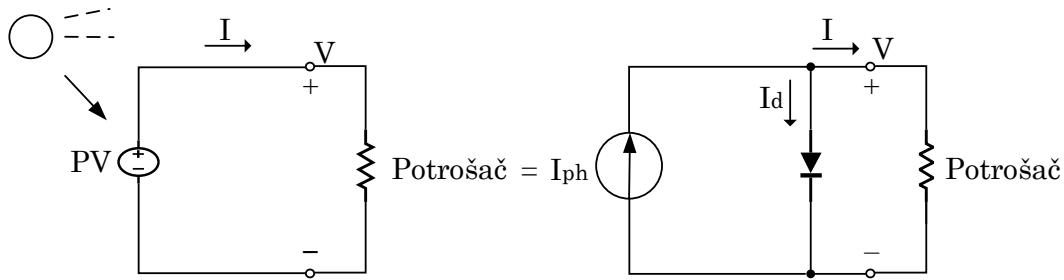
1.2 Jednodiodni model solarne ćelije

Model solarne ćelije se u praksi najčešće realizuje pomoću jednodiodnog ekvivalentnog električnog kola. Razlog tome jeste jednostavnost i zadovoljavajuća tačnost koju ovaj model obezbeđuje. Jednodiodni model solarne ćelije sadrži pet nepoznatih parametara, koji se estimiraju na osnovu informacija obezbijedjenih od strane proizvođača ili na osnovu eksperimentalno dobijenih podataka [10]. Kod većine pristupa koji se zasnivaju na upotrebi eksperimentalnih podataka, nepoznati parametri se određuju iterativnim rješavanjem prethodno formulisanog optimizacionog problema. Prednost ove tehnike jeste mogućnost dobijanja modela ćelije visoke tačnosti. S druge strane, nedostaci su visoka računska kompleksnost, pri čemu konvergencija optimizacionog algoritma nije uvijek zagarantovana [18, 19]. Za razliku od njih, model čiji se parametri određuju na osnovu informacija obezbijedjenih od strane proizvođača ćelije, je jednostavniji za implementaciju u praksi. Proizvođač najčešće daje informacije o struci kratkog spoja, naponu praznog hoda i tački maksimalne

snage ćelije, na osnovu kojih se definišu jednačine za estimaciju potrebnih parametara [19].

Različiti pristupi u implementaciji jednodiodnog ekvivalentnog modela, koji se međusobno razlikuju po svojoj tačnosti i jednostavnosti, će biti opisani u nastavku.

1.2.1 Jednodiodni idealni model solarne ćelije



Slika 1.10: Jednodiodni idealni model solarne ćelije [12]

Najjednostavniji jednodiodni model solarne ćelije se sastoji od realne diode D koja je paralelno povezana sa idealnim strujnim izvorom I_{ph} , kao što je prikazano na slici 1.10. Pri tome, idealni strujni izvor generiše struju proporcionalnu količini solarnog fluksa kojem je izložen.

Izlazna struja solarne ćelije, koja je opisana navedenim modelom, se može izraziti pomoću Kirhoffovog zakona na sljedeći način:

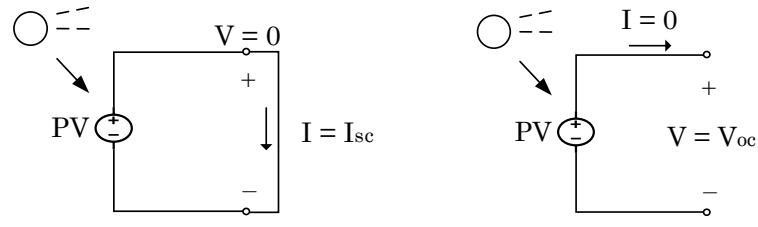
$$I = I_{ph} - I_d, \quad (1.2)$$

gdje je I_{ph} fotonaponska struja koju generiše strujni izvor, a I_d struja koja protiče kroz diodu. Pri tome, jednačina kojom se definiše struja I_d ima sljedeći oblik:

$$I_d = I_s \left[\exp\left(\frac{qV_d}{nkT_c}\right) - 1 \right], \quad (1.3)$$

gdje je I_s struja zasićenja diode [A], q količina elementarnog nanelektrisanja [= 1.602×10^{-19} C], V_d napon na diodi (koji je u ovom slučaju jednak izlaznom naponu ćelije V) [V], n faktor kvaliteta diode, k Boltmanova konstanta [= 1.381×10^{-23} J/K], a T_c stvarna temperatura solarne ćelije [K] [13].

Takođe, važno je napomenuti da se ovim modelom definišu dva slučaja od praktičnog interesa, koji se tiču kako realne solarne ćelije, tako i njenog ekvivalentnog kola (slika 1.11):

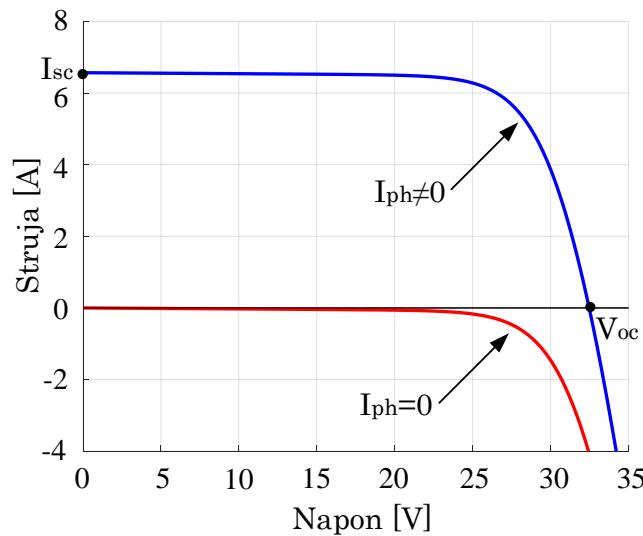


(a) Struja kratkog spoja (b) Napon praznog hoda

Slika 1.11: Značajni parametri solarne čelije [12]

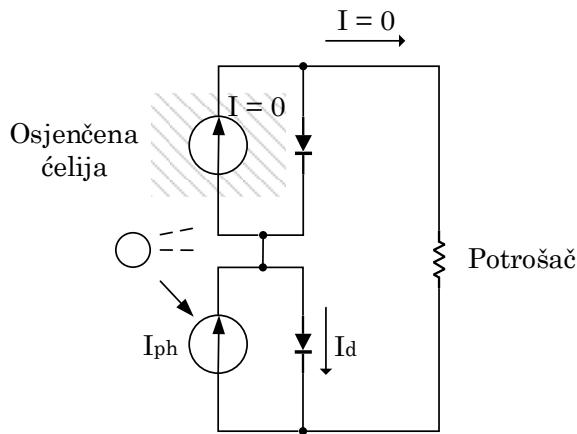
- Kratak spoj – kada su krajevi kola kratko spojeni, a kroz kolo protiče struja kratkog spoja I_{sc} . Kako u ovom slučaju ne protiče struja kroz diodu, struja I_{sc} dobija vrijednost struje I_{ph} , koju strujni izvor predaje kolu (slika 1.11a). Pri tome, struja I_{sc} predstavlja maksimalnu vrijednost struje solarne čelije.
- Prazan hod – kada su krajevi kola otvoreni. Tada se može definisati napon praznog hoda V_{oc} (slika 1.11b), koji predstavlja i maksimalnu vrijednost napona solarne čelije.

Analizom jednačine (1.2) se može izvesti zaključak o obliku I - V karakteristike solarne čelije. Struja I_{ph} je konstanta (prava linija). S druge strane, negativan predznak struje kroz diodu, I_d , izaziva rotaciju krive opisane strujom I_d i naponom V oko x-ose. Dodavanjem ove dvije karakteristike, dobija se rezultujuća karakteristika izlazne struje čelije I u zavisnosti od izlaznog napona čelije V , kao što je prikazano na slici 1.12. Konkretno, na slici su predstavljene I - V karakteristike osvijetljene čelije, kada je $I_{ph} \neq 0$, i zasjenčene čelije, kada je $I_{ph} = 0$ [13].

Slika 1.12: I - V karakteristika solarne čelije, uz prikaz njenih značajnih parametara [12]

1.2.2 Jednodiodni model solarne čelije sa paralelnom otpornosću

U praksi je često potrebno koristiti kompleksniji jednodiodni model solarne čelije, nego što je to predstavljeno slikom 1.10. Nerijetko se dešava situacija kada je jedna od serijski povezanih čelija zasjenčena. Naime, ukoliko je čelija prekrivena sjenkom (do nje ne dopiru zraci), to znači da ona ne generiše struju. Ako su čelije serijski vezane, a predstavljene jednodiodnim idealnim modelom (slika 1.10), tada je i struja koju generišu druge osvjetljene čelije jednak nuli, $I_{ph} = 0$, što u praksi ne može biti slučaj. Razlog tome jeste nemogućnost provođenja struje I_{ph} kroz zasjenčenu čeliju – dioda, koja se nalazi u grani paralelnoj sa granom strujnog izvora, je postavljena u takvom smjeru da ne dozvoljava provođenje struje od drugih, serijski vezanih, osvjetljenih čelija. Navedena situacija je predstavljena slikom 1.13, gdje je dat primjer dvije serijski povezane solarne čelije sa opterećenjem [13].



Slika 1.13: Jednostavno kolo serijski povezanih solarnih čelija, koje prikazuje slučaj zasjenčenja jedne od čelija kada struja ne može proteći do opterećenja [12]

Opisani problem se može riješiti vezivanjem otpornosti R_p paralelno strujnom izvoru. U tom slučaju, struja koju generišu osvjetljene čelije može proteći i kroz zasjenčenu čeliju (kroz granu sa otpornošću R_p), a zatim doći do potrošača. Takav model solarne čelije sa otpornošću R_p je prikazan na slici 1.14.

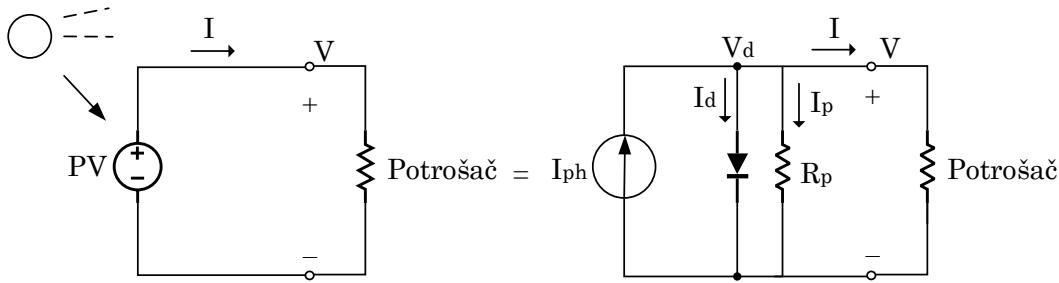
Izlazna struja ovako definisanog modela solarne čelije sada ima oblik:

$$I = I_{ph} - I_d - I_p, \quad (1.4)$$

gdje je I_p struja koja protiče kroz paralelnu otpornost, a koja se definiše odnosom izlaznog napona V i otpornosti R_p :

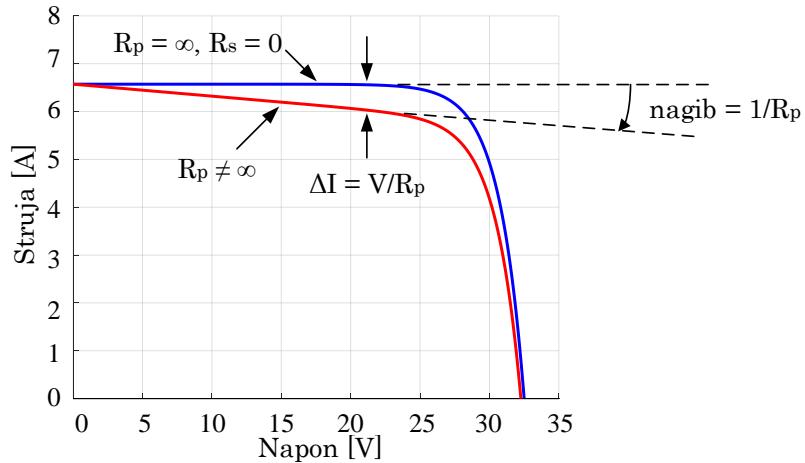
$$I_p = \frac{V}{R_p}. \quad (1.5)$$

Pri tome, paralelnom otpornošću R_p su opisane nečistoće i mikrodefekti unutar solarne čelije, koji zavise od njenih osobina.



Slika 1.14: Jednodiodni model solarne ćelije sa paralelnom otpornošću [12]

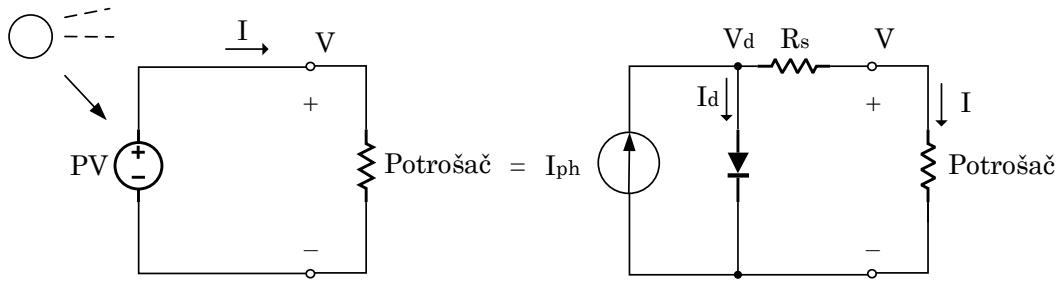
Na slici 1.15 je prikazana I - V karakteristika solarne ćelije sa dodatom paralelnom otpornošću R_p , koja urokuje blagi nagib ove karakteristike [13].



Slika 1.15: I - V karakteristika solarne ćelije sa dodatom paralelnom otpornošću [12]

1.2.3 Jednodiodni model solarne ćelije sa serijskom otpornošću

Jednodiodnom idealnom modelu solarne ćelije se, takođe, može dodati serijska otpornost R_s , koja u praksi predstavlja otpornost između P i N slojeva solarne ćelije. Takav model je prikazan na slici 1.16.



Slika 1.16: Jednodiodni model solarne ćelije sa serijskom otpornošću [12]

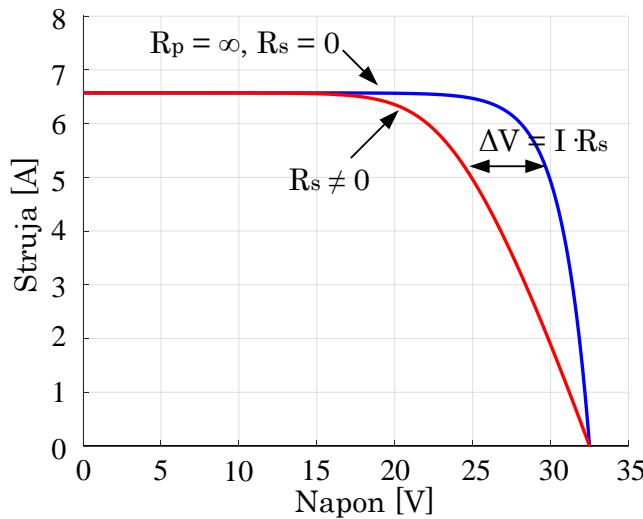
Izlazna struja ovog modela solarne ćelije dobija oblik:

$$I = I_{ph} - I_d = I_{ph} - I_s \left[\exp\left(\frac{qV_d}{nkT_c}\right) - 1 \right], \quad (1.6)$$

gdje napon na diodi V_d predstavlja zbir izlaznog napona V i napona na dodatoj serijskoj otpornosti:

$$V_d = V + IR_s. \quad (1.7)$$

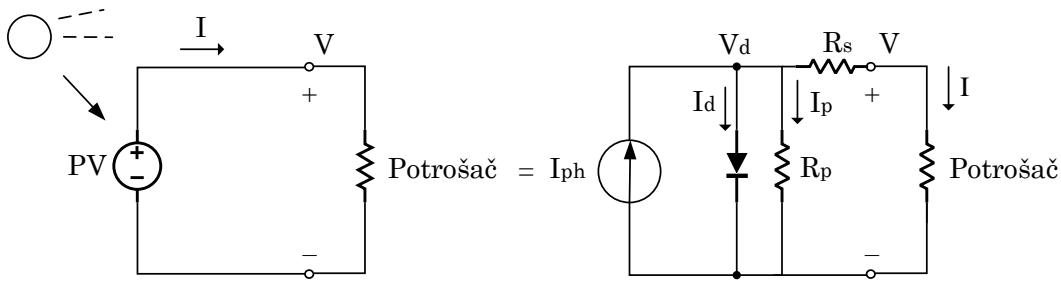
Dakle, dodavanje otpornosti R_s uzrokuje pomjeranje I - V karakteristike duž V -ose, kao što je predstavljeno slikom 1.17 [13].



Slika 1.17: I - V karakteristika solarne ćelije sa dodatom serijskom otpornošću [12]

1.2.4 Kompletan jednodiodni model solarne ćelije

Najprecizniji jednodiodni model solarne ćelije se može dobiti dodavanjem i paralelne, R_p , i serijske otpornosti, R_s (slika 1.18).



Slika 1.18: Jednodiodni model solarne ćelije sa paralelnom i serijskom otpornošću [12]

Jednačina kojom se opisuje izlazna struja solarne ćelije predstavljene navedenim modelom, ima sljedeći oblik:

$$I = I_{ph} - I_d - I_p, \quad (1.8)$$

gdje je struja diode definisana jednačinom:

$$I_d = I_s \left[\exp\left(\frac{q(V + IR_s)}{nkT_c}\right) - 1 \right], \quad (1.9)$$

S druge strane, struja I_p se definiše na sljedeći način [20]:

$$I_p = \frac{V + IR_s}{R_p}, \quad (1.10)$$

Uvrštavanjem jednačina (1.9) i (1.10) u jednačinu (1.8), dobija se izraz za izlaznu struju ćelije:

$$I = I_{ph} - I_s \left[\exp\left(\frac{q(V + IR_s)}{nkT_c}\right) - 1 \right] - \frac{V + IR_s}{R_p}. \quad (1.11)$$

U cilju pojednostavljenja jednačine (1.11), u praksi se često koristi njena aproksimacija dobijena pomoću idealnog jednodiodnog modela ćelije u slučaju kratkog spoja:

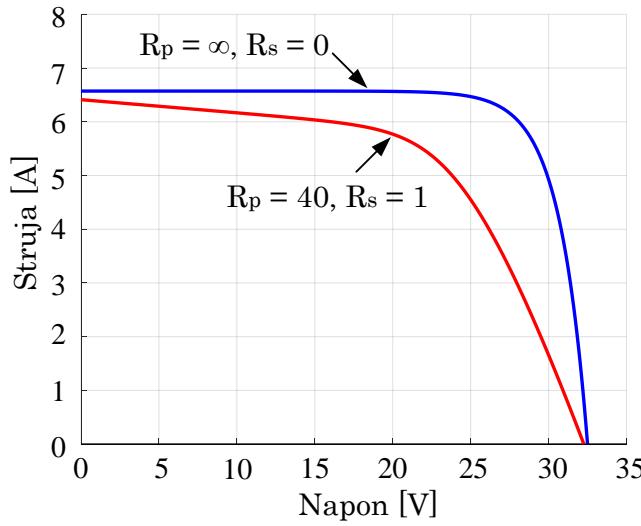
$$I_{ph} \approx I_{sc}, \quad (1.12)$$

gdje je I_{sc} struja kratkog spoja ćelije, čiju vrijednost zadaje proizvođač ćelije.

Uzimajući u obzir jednakost (1.12), jednačina (1.11) se sada može izraziti kao:

$$I = I_{sc} - I_s \left[\exp\left(\frac{q(V + IR_s)}{nkT_c}\right) - 1 \right] - \frac{V + IR_s}{R_p}. \quad (1.13)$$

$I-V$ karakteristika solarne ćelije koja je definisana jednačinom (1.13), prikazana je na slici 1.19:



Slika 1.19: I - V karakteristika solarne ćelije sa dodatom paralelnom i serijskom otpornošću [12]

Česta je situacija kada se može zanemariti efekat otpornosti R_p . U praksi ona ima velike vrijednosti, te uslovljava malu struju I_p . Ukoliko se pretpostavi da je $R_p = \infty$, tada jednačina (1.13) dobija sljedeći oblik:

$$I = I_{sc} - I_s \left[\exp\left(\frac{q(V + IR_s)}{nkT_c}\right) - 1 \right]. \quad (1.14)$$

Može se primijetiti da je I - V karakteristika solarne ćelije, zadata jednačinom (1.14), definisana u implicitnom obliku. Iz tog razloga, njeno rješavanje zahtijeva primjenu neke od iterativnih metoda. Iako bi bilo moguće naći rješenje pomoću jednostavnijih iterativnih metoda, najčešće se pribjegava upotrebi Njutn-Rapsonove (eng. *Newton-Raphson*) metode, koja obezbjeđuje brzu konvergenciju rješenju. Njutn-Rapsonova metoda je opisana sljedećim izrazom [20]:

$$x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)}, \quad (1.15)$$

gdje je $f'(x)$ izvod funkcije $f(x) = 0$, x_n je njena trenutna vrijednost, a x_{n+1} prva sljedeća vrijednost.

Jednačina (1.14) se može zapisati u obliku:

$$f(I) = I_{sc} - I - I_s \left[\exp\left(\frac{q(V + IR_s)}{nkT_c}\right) - 1 \right] = 0. \quad (1.16)$$

U skladu sa izrazom (1.15), jednačina (1.16) dobija rekurzivni oblik, pri čemu se struja I računa iterativno [20, 21]:

$$I_{n+1} = I_n - \frac{I_{sc} - I_n - I_s \left[\exp\left(\frac{q(V + I_n R_s)}{nkT_c}\right) - 1 \right]}{-1 - I_s \left(\frac{qR_s}{nkT_c} \right) \exp\left(\frac{q(V + I_n R_s)}{nkT_c}\right)}. \quad (1.17)$$

Takođe, bitno je navesti da parametri solarne ćelije/panela zavise od vremenskih uslova, najviše od solarne iradijanse G i temperature T . Pri tome, parametri I_{ph} , I_s , R_p , R_s i n za različite uslove rada se mogu izraziti pomoću sljedećih jednačina [22]:

$$I_{ph} = (I_{ph,ref} + \alpha(T - T_{ref})) \frac{G}{G_{ref}}, \quad (1.18)$$

$$I_s = I_{s,ref} \left(\frac{T}{T_{ref}} \right)^3 \exp \left(\frac{E_{g,ref}}{kT_{ref}} - \frac{E_g}{kT} \right), \quad (1.19)$$

$$R_p = R_{p,ref} \left(\frac{G}{G_{ref}} \right), \quad (1.20)$$

$$R_s = R_{s,ref}, \quad (1.21)$$

$$n = n_{ref}, \quad (1.22)$$

gdje se indeks *ref* odnosi na vrijednosti parametara mjerenih pri standardnim uslovima za testiranje (eng. *Standard Test Conditions* – STC, koji su definisani ambijentalnom temperaturom 25°C i iradijansom 1000 W/m²), α strujno/temperaturni koeficijent kratkog spoja, a E_g band-gap energija poluprovodnika:

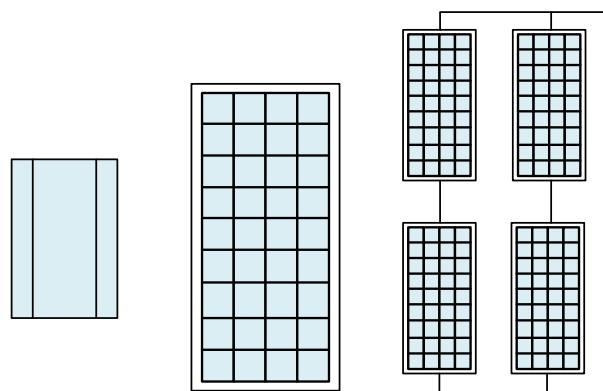
$$E_g = 1.17 - 4.73 \times 10^{-4} \times \frac{T^2}{T + 636} [\text{eV}]. \quad (1.23)$$

1.2.5 Definicija solarne ćelije, modula i panela. Jednodiodni model solarnog panela

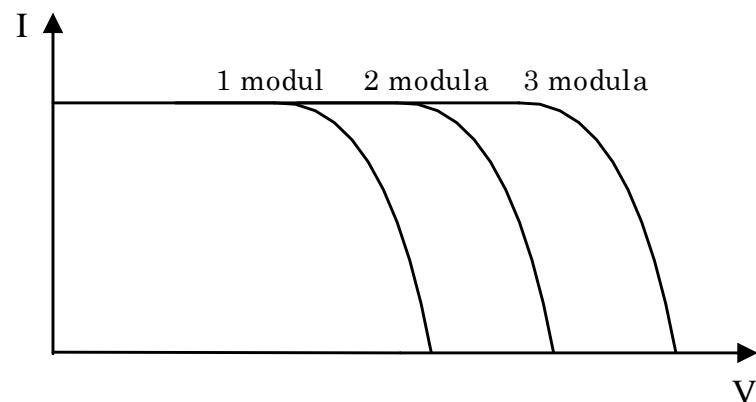
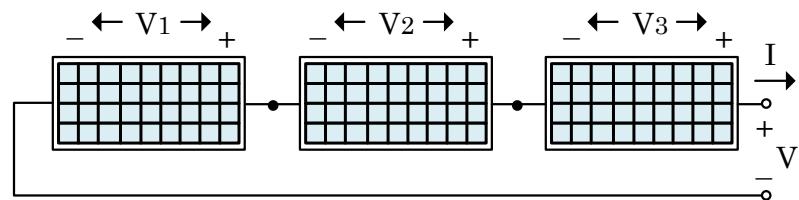
Solarna ćelija se može smatrati osnovnim dijelom modula i panela. Međutim, kako ona generiše samo oko 0.5V, gotovo nikada se ne upotrebljava samostalno. Iz tog razloga, osnovni sastavni PV blok predstavlja modul, koji se sastoji od više serijski ili paralelno povezanih ćelija. Najčešće se primjenjuju 12V moduli, koje čine 36 serijski povezanih ćelija. Takođe, danas se široko primjenjuju moduli koji se sastoje od 72 ćelije, a koje se mogu prespajati zavisno od željenog izlaznog napona – ukoliko se sve 72 ćelije povežu serijski, tada se dobija 24V modul, odnosno, ako se povežu dva paralelna niza od po 36 serijski vezanih ćelija, dobija se 12V modul. Na slici 1.20 su prikazani solarna ćelija, modul i panel, kako bi se jasno mogla utvrditi razlika među njima.

Opisani moduli se dalje povezuju u panele, pri čemu se serijskim vezivanjem modula dobija veći izlazni napon, a njihovim paralelnim vezivanjem veća izlazna struja. Stoga, posebna pažnja se posvećuje dizajniranju PV sistema – odlučivanju koliko modula treba povezati serijski, a koliko paralelno, tako da se na izlazu generiše potrebna energija. U slučaju serijski povezanih modula, za datu struju koja protiče kroz sve module, ukupan izlazni napon predstavlja sumu napona na pojedinim modulima. Zavisno od promjene vrijednosti izlaznog napona, I - V kriva se jednostavno pomjera duž V -ose. Opisani slučaj je prikazan na slici 1.21. S druge strane, u slučaju paralelno povezanih modula, isti napon se nalazi na svim modulima, a ukupna izlazna struja predstavlja zbir struja koje protiču kroz svaki modul. Prema tome, za dati napon, a različite vrijednosti izlazne struje, I - V kriva se pomjera duž I -ose, što je prikazano na slici 1.22.

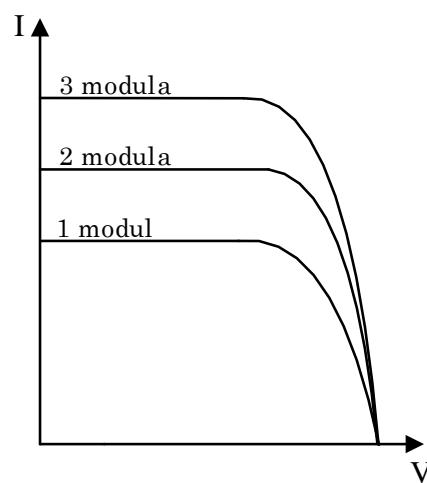
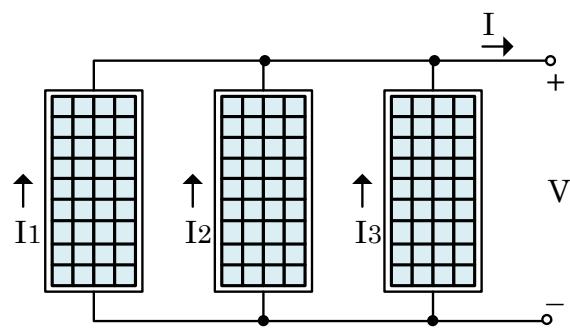
Kada je potrebna visoka izlazna snaga, uglavnom se vrši kombinacija serijski i paralelno povezanih modula pri kreiranju panela, tako da konačna $I-V$ kriva predstavlja sumu $I-V$ krivih pojedinačnih modula. Postoje dva načina za njihovo povezivanje. Prvi, kada se serijski moduli najprije povežu u nizove, a zatim se ti nizovi povežu paralelno (slika 1.23a); drugi, kada se paralelno vezani moduli kombinuju u serijsku vezu (slika 1.23b). Međutim, u praksi se najčešće pribjegava prvom načinu. Razlog tome jeste mogućnost uklanjanja niza serijskih modula (npr. u slučaju kvara), a da pri tome panel i dalje vrši napajanje opeterećenja potrebnim naponom [13].



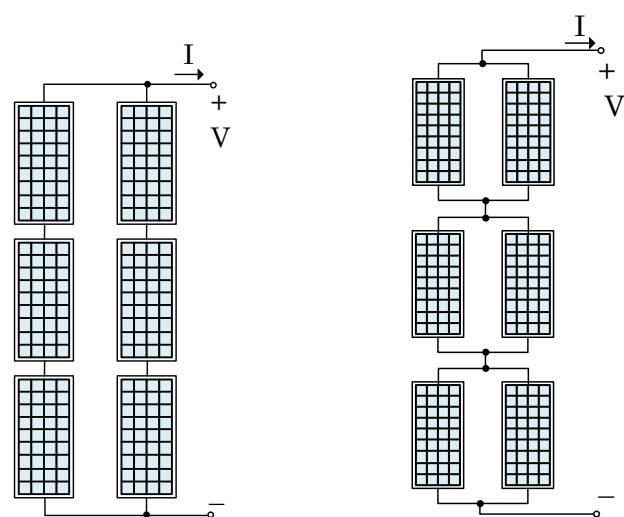
Slika 1.20: Solarna čelija, modul i panel



Slika 1.21: Povećanje izlaznog napona uslijed serijski povezanih modula

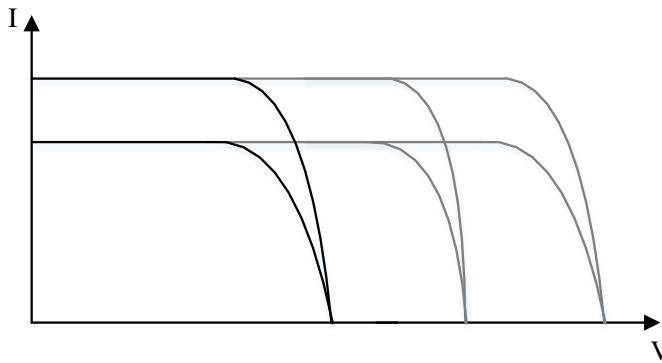


Slika 1.22: Povećanje izlazne struje uslijed paralelnog povezivanja modula



(a) Paralelna veza serijski povezanih modula

(b) Serijska veza paralelno povezanih modula



(c) Rezultujuća I - V kriva panela prikazanog na slici 1.23a, odnosno na slici 1.23b

Slika 1.23: Povezivanje modula u panel

Na kraju, važno je naglasiti da ekvivalentno kolo solarnog panela ima istu strukturu kao i kolo kojim se predstavlja solarna ćelija (slika 1.18) [20], pri čemu serijsko, odnosno paralelno vezivanje modula ima uticaj na parametre modela solarnog panela. Naime, ekvivalentna otpornost panela se mijenja u zavisnosti od broja serijski i paralelno povezanih modula, pa je u cilju definisanja izraza za izlaznu struju panela potrebno uvesti određene promjene u jednačinu (1.13). Prema tome, jednačina za izlaznu struju panela ima sljedeći oblik:

$$I = I_{sc}N_{pp} - I_s N_{pp} \left[\exp \left(\frac{V + IR_s \left(\frac{N_{ss}}{N_{pp}} \right)}{nV_t N_{ss}} \right) - 1 \right] - \frac{V + IR_s \left(\frac{N_{ss}}{N_{pp}} \right)}{R_p \left(\frac{N_{ss}}{N_{pp}} \right)}, \quad (1.24)$$

gdje N_{ss} predstavlja broj serijski povezanih modula, N_{pp} broj paralelno povezanih modula, a V_t termalni napon diode koji je definisan jednačinom [23]:

$$V_t = \frac{N_s k T_c}{q}, \quad (1.25)$$

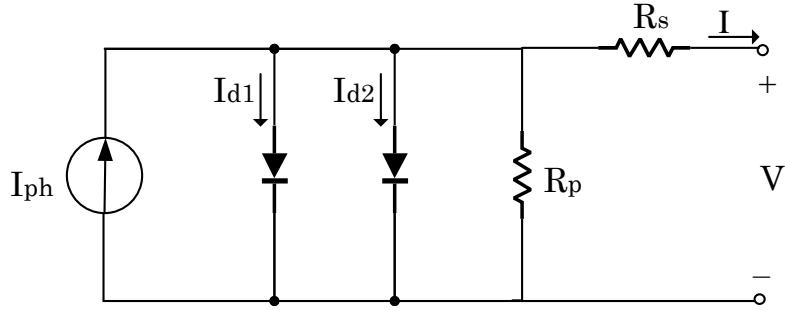
gdje je N_s broj serijski povezanih ćelija u jednom modulu.

1.3 Dvodiodni model solarne ćelije

Za razliku od jednodiodnog modela, dvodiodni model se sastoji od dvije diode, čime se povećava preciznost samog modela, naročito pri nižim vrijednostima iradijanse. S druge strane, povećava se broj nepoznatih parametara, pa samim tim i računska kompleksnost modela [24, 25, 26]. Jednačine za estimaciju parametara su implicitne i nelinearne, što onemogućava njihovo rješavanje analitičkim pristupom. Postoje dvije glavne metode za rješavanje ovih jednačina. Prvi metod je baziran na prilagođavanju teoretski određenih I - V krivih onima koje su eksperimentalno dobijene, dok drugi metod omogućava definisanje parametara na osnovu određenih ključnih tačaka I - V krive iz eksperimentalnih podataka [24, 27, 28, 29, 30]. Drugi metod se široko primjenjuje u industriji zbog brzine rješavanja i lako dostupnih

neophodnih podataka (oni su definisani u proizvodnim katalozima solarnih panela). Ipak, njegova negativna strana jeste potreba za odgovarajućom početnom tačkom kako bi se osigurala konvergencija rješenju jednačine [19].

Na slici 1.24 je prikazano dvodiodno ekvivalentno električno kolo solarne ćelije.



Slika 1.24: Dvodiodni model solarne ćelije

Jednačina (1.26) definiše izlaznu struju ćelije predstavljene ovim modelom:

$$I = I_{ph} - I_{d1} - I_{d2} - \left(\frac{V + IR_s}{R_p} \right), \quad (1.26)$$

gdje su struje I_{d1} i I_{d2} određene na sljedeći način:

$$I_{d1} = I_{s1} \left[\exp \left(\frac{(V + IR_s)}{n_1 V_t} \right) - 1 \right], \quad (1.27)$$

$$I_{d2} = I_{s2} \left[\exp \left(\frac{(V + IR_s)}{n_2 V_t} \right) - 1 \right], \quad (1.28)$$

gdje su I i V izlazna struja i izlazni napon solarne ćelije, I_{s1} struja zasićenja dioda koja se javlja uslijed difuzije slobodnih nosilaca nanelektrisanja, I_{s2} struja zasićenja diode koja se javlja uslijed rekombinacije nosilaca nanelektrisanja u oblasti prostornog tovara, n_1 faktor kvaliteta diode za difuzionu struju, n_2 faktor kvaliteta diode za struju koja se javlja uslijed rekombinacije nosilaca nanelektrisanja, R_s i R_p serijska i paralelna otpornost, a V_t termalni napon diode definisan jednačinom koja je ekvivalentna sa (1.25) [31].

U cilju smanjenja kompleksnosti jednačine (1.26), u praksi se često vrši aproksimacija vrijednosti faktora kvaliteta diode $n_1 = 1$ i $n_2 = 2$ na osnovu Shockley-jeve difuzione teorije, pri čemu je očuvana tačnost modela [24, 26, 29, 30, 32, 33]. Međutim, postoje izuzeci kada se ovaj pristup ipak ne pokazuje tačnim [25, 34]. Dakle, na osnovu uvedenih aproksimacija, jednačina (1.25) dobija sljedeći oblik:

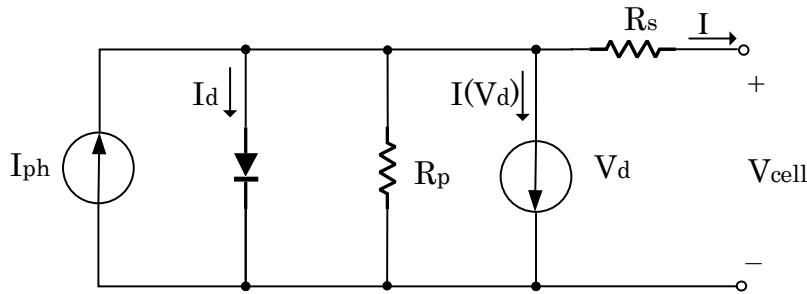
$$I = I_{ph} - I_{s1} \left[\exp \left(\frac{(V + IR_s)}{V_t} \right) - 1 \right] - I_{s2} \left[\exp \left(\frac{(V + IR_s)}{2V_t} \right) - 1 \right] - \left(\frac{V + IR_s}{R_p} \right). \quad (1.29)$$

Na ovaj način, broj nepoznatih parametara je smanjen sa 7 (jednačina (1.26)) na 5 (jednačina (1.29)). Primjenom prethodno opisanog metoda, koji uključuje upotrebu poznatih podataka iz proizvodnih kataloga solarnih panela, moguće je odrediti nepoznate parametre R_s , R_p , I_{s1} , I_{s2} , I_{ph} . Najčešće se koriste podaci definisani za standardne testne uslove (eng. *Standard Test Conditions* – STC), i to: napon praznog hoda V_{oc} , struja kratkog spoja I_{sc} , napon u tački maksimalne snage (eng. *Maximal Power Point* – MPP) V_{mpp} , i struja u tački maksimalne snage I_{mpp} [19].

1.4 Modifikovani jednodiodni model solarne ćelije

Sve prethodno definisane tehnike imaju smisao jedino u slučajevima kada je iradijansa uniformno raspoređena, odnosno u uslovima kada se jednačine solarne ćelije mogu primijeniti na cijeli solarni panel. Dodatno, strujno-naponske jednačine solarne ćelije kod jednodiodnog i dvodiodnog modela su zadate u implicitnom obliku, pa je za njihovo rješavanje potrebno upotrijebiti iterativnu Njutn-Rapsonovu metodu. Da bi se izbjeglo iterativno rješavanje jednačina, uveden je model solarne ćelije kod kojeg se Lambertova funkcija W koristi za dobijanje eksplicitne zavisnosti izlazne struje ćelije od izlaznog napona [38]. Takođe, taj pristup je moguće generalizovati na cijeli solarni panel [39], što je opisano u nastavku.

Usvojeni model, na kojem je zasnovan ovaj pristup, prikazan je na slici 1.25. On zapravo predstavlja unaprijeđen oblik jednodiodnog modela sa slike 1.18, pri čemu omogućava preciznije predstavljanje radnih stanja diode. Konkretno, strujno-naponske karakteristike prethodnih modela su uzimale u obzir samo stanje direktnе polarizacije diode, dok je ovim modelom opisano i stanje inverzne polarizacije i proboga [39, 40, 41, 42, 43].



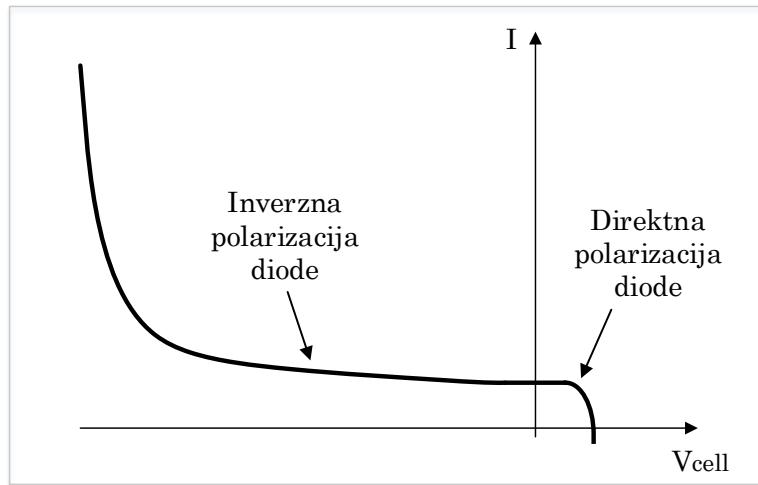
Slika 1.25: Unaprijeđeni jednodiodni model solarne ćelije

Jednačina izlazne struje definisana na osnovu navedenog modela, ima sljedeći oblik:

$$I = I_{ph} - I_s \left[\exp \left(\frac{V_{cell} + IR_s}{V_t} \right) - 1 \right] - \frac{V_{cell} + IR_s}{R_p} - b (V_{cell} + IR_s) \left(1 - \frac{V_{cell} + IR_s}{V_{br}} \right)^{-m}, \quad (1.30)$$

gdje parametri I_{ph} , I_s , V_t , R_s i R_p predstavljaju pet nepoznatih parametra modela koji se mogu odrediti iterativnim rješavanjem, na način predstavljen u sekciji 1.2.4 [39]. S druge strane, koeficijenti b , V_{br} i m služe za modelovanje stanja čelije pri negativnom naponu, odnosno stanja inverzne polarizacije i probaja, što je od posebnog značaja za analizu djelimičnog zasjenčenja čelije. Oni su definisani vrijednostima koje se najčešće usvajaju u praksi [40, 41, 42]: $b = 0.002\Omega^{-1}$, $V_{br} = -21.99V$ i $m = 3$. Dakle, drugi član ove jednačine predstavlja slučaj direktnе polarizacije, kada dioda provodi struju, a posljednji član slučaj negativnog napona.

I - V karakteristika solarne čelije određene jednačinom (1.30) je prikazana na slici 1.26:



Slika 1.26: I - V karakteristika unaprijeđenog jednodiodnog modela solarne čelije

1.4.1 Eksplisitni oblik modela čelije

Kao što je prethodno navedeno, jednačinu (1.30) je moguće zapisati u eksplisitnom obliku $V_{cell} = f(I)$ pomoću Lambertove funkcije W , te na taj način izbjegći njeno iterativno rješavanje.

Najprije se definiše jednostavniji oblik jednačine (1.30) na osnovu sljedećih pretpostavki. Za vrijeme stanja negativnog napona, vrijednost eksponencijalnog člana kojim je predstavljena direktna polarizacija diode, ima vrijednost približnu nuli zato što je tada dioda D inverzno polarisana. S druge strane, kada je prisutan pozitivan napon, posljednji član ove jednačine nema praktični smisao. Prema tome, osnovna jednačina čelije može biti modifikovana tako da različiti izrazi predstavljaju različita radna stanja čelije, što je prikazano u (1.31):

$$I = \begin{cases} I_{ph} - I_s \left[\exp \left(\frac{V_{cell} + IR_s}{V_t} \right) - 1 \right] - \frac{V_{cell} + IR_s}{R_p}, & V_{cell} \geq 0 (I \leq I_{ph}) \\ I_{ph} - \frac{V_{cell} + IR_s}{R_p} - b(V_{cell} + IR_s) \left(1 - \frac{V_{cell} + IR_s}{V_{br}} \right)^{-m}, & V_{cell} < 0 (I > I_{ph}) \end{cases} \quad (1.31)$$

Za pozitivne napone, jednačina (1.31) je ekvivalentna sa jednačinom osnovnog jednodiodnog modela ćelije, koja može biti riješena upotrebom Lambertove funkcije W na sljedeći način:

$$V_{cell} = R_p (I_{ph} + I_s) - (R_s + R_p) I - V_t W \left\{ \frac{R_p I_s}{V_t} \exp \left(\frac{R_p (I_{ph} + I_s - I)}{V_t} \right) \right\}, \quad (1.32)$$

pri čemu su aproksimacije korištene za proračun $W(x)$ detaljno opisane u [39].

Za negativne napone, jednačina (1.31) se može zapisati u obliku jednačine četvrtog reda, pod uslovom da se usvoji vrijednost $m = 3$:

$$\frac{1}{R_p} z^4 + \left(I_{ph} - I - \frac{V_{br}}{R_p} \right) z^3 + b V_{br}^3 z - b V_{br}^4 = 0 \quad (1.33)$$

gdje je $z = V_{br} - V_{cell} - IR_s$ [39].

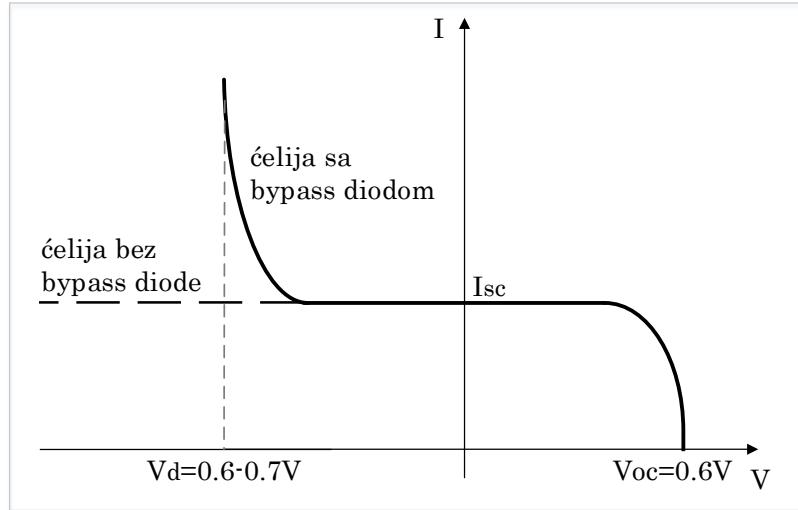
Izlazni napon ćelije V sada predstavlja minimalni realni korijen polinomijalne jednačine (1.33), $z_{R_{min}} = \min\{\text{real}\{z\}\}$, koji se može odrediti primjenom brzog i robustnog Ferarijevog (eng. *Ferrari*) metoda za rješavanje jednačina četvrtog reda [44]. Iako se najčešće uzima vrijednost $m = 3$ [40, 41, 42], predlaže se i usvajanje drugih vrijednosti za m , i to iz opsega od 3 do 6 [43, 45, 46, 47]. U tom slučaju, jednačina (1.33) bi dobila oblik polinomijalne jednačine višeg reda koja se, takođe, može numerički riješiti. Međutim, taj način ne bi bio toliko efikasan kao primjena eksplisitne Ferarijeve formule.

Konačno, jednačine solarne ćelije za slučaj pozitivnog napona (u eksplisitnom obliku), kao i za slučaj negativnog napona, su opisane sljedećim izrazima [39]:

$$V_{cell} = \begin{cases} R_p (I_{ph} + I_s) - (R_s + R_p) I - V_t W \left\{ \frac{R_p I_s}{V_t} \exp \left(\frac{R_p (I_{ph} + I_s - I)}{V_t} \right) \right\}, & I \leq I_{ph} \\ V_{br} - IR_s - z_{R_{min}}, & I > I_{ph} \end{cases} \quad (1.34)$$

1.4.2 Eksplisitni oblik modela panela

U solarnim modulima, koji se sastoje od serijski povezanih ćelija, može se javiti problem kada se neka od ćelija nađe u sjenci. Tada, kroz zasjenčenu ćeliju teče veća struja od one koju ona može da generiše, na njoj se javlja negativni napon, te postaje inverzno polarisana. Dodatnim povećanjem struje kroz ovu ćeliju dolazi do njenog zagrijavanja, što može izazvati pojavu "vruće tačke" (eng. *hot spot*) i time njeno oštećenje [13]. Iz tog razloga, paralelno sa nizom serijski povezanih ćelija se ugrađuju tzv. bypass diode, koje sprječavaju nastanak visokih negativnih napona na ćelijama i pojavu "vruće tačke". Konkretno, kada vrijednost negativnog napona dostigne vrijednost V_{cs} (uglavnom oko 0.6V-0.7V), tada ova dioda počinje da provodi struju. $I-V$ karakteristika solarne ćelije bez i sa bypass diodom je prikazana na slici 1.27, gdje se jasno može uočiti značaj ove diode.



Slika 1.27: I - V karakteristika niza serijski povezanih ćelija, sa i bez bypass diode

Tačna vrijednost V_{cs} se može odrediti pomoću jednačine bypass diode, pri čemu se prepostavlja da niz ćelija radi pri praktično konstantnoj struci kratkog spoja $I_{sc,cs}$. Tada, bypass dioda provodi struju koja je jednaka razlici ukupne struje niza ćelija I i $I_{sc,cs}$. Prema tome, za datu struju I , napon V_{cs} se može izračunati na sljedeći način:

$$V_{cs} = \begin{cases} \sum_{i=1}^{N_s} V_{cell-i}(I), & I \leq I_{sc,cs} \\ -a_{bp} \ln \left(\frac{I - I_{sc,cs}}{I_{sbp}} + 1 \right) & I > I_{sc,cs}. \end{cases} \quad (1.35)$$

U prvom i četvrtom kvadrantu, napon niza ćelija je predstavljen sumom napona na pojedinim ćelijama V_{cell-i} , što je dato jednačinom (1.34). U drugom kvadrantu, za vrijednost $I_{sc,cs}$ se može uzeti minimalna vrijednost struje kratkog spoja određene ćelije iz niza, koja se aproksimira vrijednošću odgovarajuće generisane struje I_{ph} .

Solarni modul, koji se sastoji od N_{cs} serijski povezanih nizova ćelija, je opisan jednačinom:

$$V_{mod} = \sum_{i=1}^{N_{cs}} V_{cs-i}(I), \quad (1.36)$$

dok je niz od N_m serijski povezanih modula, predstavljen jednačinom:

$$V_{str} = \sum_{i=1}^{N_m} V_{mod-i}(I). \quad (1.37)$$

Na ovaj način, definisan je eksplicitan oblik modela niza modula, gdje izlazni napon niza predstavlja funkciju od izlazne struje [39].

S druge strane, određivanje modela solarnog panela, koji se sastoji od paralelno povezanih nizova modula, se može izvršiti na dva načina. Prvi način se odnosi na određivanje I - V karakteristike svakog niza pojedinačno, nakon čega se vrši njihova grafička superpozicija, kako bi se dobila I - V karakteristika cijelog panela [48]. Drugi

način podrazumijeva iterativno rješavanje jednačina pojedinih nizova za dati izlazni napon, a nakon toga sumiranje njihovih struja kako bi se dobila konačna izlazna struja [49].

Prvi pristup uključuje upotrebu prethodno definisanog modela niza modula (jednačina (1.37)), čime se određuje eksplicitna I - V karakteristika pojedinačnih nizova. Dalje se vrši superpozicija dobijenih krivih za zajedničku V -osu, a radna tačka na konačnoj krivoj panela se računa primjenom linearne interpolacije. Iako ovaj pristup podrazumijeva proračun više radnih tački na I - V krivoj, njegova računska kompleksnost je zanemarljiva zato što se vrše jednostavne algebarske operacije.

Drugi pristup se odnosi na numeričko rješavanje jednačine (1.37) za svaki niz modula pojedinačno, pri određenom izlaznom naponu. To uključuje primjenu iterativnog metoda, npr. Njutn-Rapsonovog metoda, čime se određuju izlazne struje pojedinih nizova. Na kraju, sumiranjem ovih struja se dobija rezultujuća izlazna struja panela. Negativna strana ovog pristupa je veća računska kompleksnost i problemi sa postizanjem konvergencije ka rješenju. Ipak, on može biti primjenljiv u praksi zato što je potrebno riješiti mali broj nezavisnih jednačina (jedna po nizu modula) [39].

1.5 Model efikasnosti solarne ćelije

Za razliku od prethodno opisanih matematičkih modela solarne ćelije, postoje i modeli koji su razvijeni na osnovu eksperimentalnih rezultata. Dokazano je da poznavanje podataka iz proizvodnog kataloga solarnog panela nije dovoljno pri odbiru odgovarajućeg tipa panela za klimatske uslove određenog područja, gdje se tip panela odnosi na panele napravljene od različitih materijala (monokristalni, polikristalni, amorfni silikonski, itd.) [35]. Iz tog razloga, definisan je model efikasnosti solarne ćelije/panela, koji omogućava računanje efikasnosti ćelija i panela pri različitim klimatskim uslovima, kao i predikciju proizvedene energije [36].

Efikasnost η je određena funkcijom:

$$\eta = f(G, T_c, AM), \quad (1.38)$$

gdje G predstavlja globalnu normalnu iradijansu, T_c temperaturu ćelije i AM relativnu masu vazduha. Ovi parametri se mogu odrediti pomoću I - V karakteristike panela, pa je najprije potrebno izvršiti mjerjenje ovih karakteristika [37]. Pri tome, mjerjenje se vrši pri svim mogućim klimatskim uslovima, odnosno pri svim vrijednostima ambijentalne temperature T_a , temperature ćelije T_c i globalne normalne iradijanse G , koje se mogu javiti na površini panela. Takođe, zabilježavaju se i dan, mjesec i godina kada su izvršena mjerjenja, koji će kasnije biti potrebni za proračun relativne mase vazduha. Dakle, na ovaj način je moguće definisati efikasnost za sve moguće kombinacije izmjerениh vrijednosti temperature ćelije, iradijanse i relativne mase vazduha [36].

Usvojeni model efikasnosti panela je predstavljen jednačinom:

$$\eta = p \left[q \frac{G}{G_0} + \left(\frac{G}{G_0} \right)^m \right] \times \left[1 + r \frac{T_c}{T_{c0}} + s \frac{AM}{AM_0} + \left(\frac{AM}{AM_0} \right)^u \right], \quad (1.39)$$

gdje je $G_0 = 1000 \text{ W/m}^2$, $T_{c0} = 25^\circ\text{C}$ i $AM_0 = 1.5$. Parametre p, q, m, r i u je potrebno odrediti za svaki tip panela iz dobijenog seta mjerenja. Glavne pretpostavke na osnovu kojih je razvijen model efikasnosti (jednačina (1.39)) su:

1. Efikasnost η ima vrijednost nula kada je iradijansa G jednaka nuli,
2. Efikasnost je linearna funkcija temperature celije T_c pri konstantnoj iradijansi G i konstantnoj relativnoj mase vazduha AM ,
3. Efikasnost može biti i nelinearna funkcija od relativne mase vazduha AM .

Dakle, rješavanje jednačine (1.39) uključuje proračune za AM , T_c , kao i za parametre p, q, m, r i u . Relativna masa vazduha AM se određuje na osnovu datuma i vremena u toku dana, kao i geografskih koordinata određenog područja. Temperaturni model panela se može izraziti pomoću jednačine [36]:

$$T_c = T_a + hG, \quad (1.40)$$

gdje je T_c temperatura celije, T_a ambijentalna temperatura, G globalna normalna iradijansa, a h Rosov (eng. Ross) koeficijent koji se definiše za određen tip panela [37]. Kako su izvršena mjerena za T_c, T_a i G , na osnovu jednačine (1.40) se može izračunati vrijednost Rosovog koeficijenta, koji je bitan za buduće određivanje temperature celija, jer su u meteorološkim bazama dostupna samo mjerena za G i T_a . S druge strane, parametri p, q, m, r i u se proračunavaju za određen tip panela na osnovu nelinearnog metoda najmanjih kvadrata (eng. *Least Squares Fitting method*) [36].

Sada je moguće izvršiti predikciju proizvedene energije panela, $E_m[\text{kWh}]$. Meteorološki podaci posmatranog područja, kao i njegove geografske koordinate, omogućavaju proračun temperature celije T_c i relativne mase vazduha AM kao funkciju od vremena. Ove vrijednosti se uvrštavaju u jednačinu modela efikasnosti (1.39), čime se računa efikasnost η određenog tipa panela na posmatranom području. Dalje, snaga panela $P[\text{W}]$ se može odrediti pomoću izraza:

$$P(t) = \eta(t)AG(t), \quad (1.41)$$

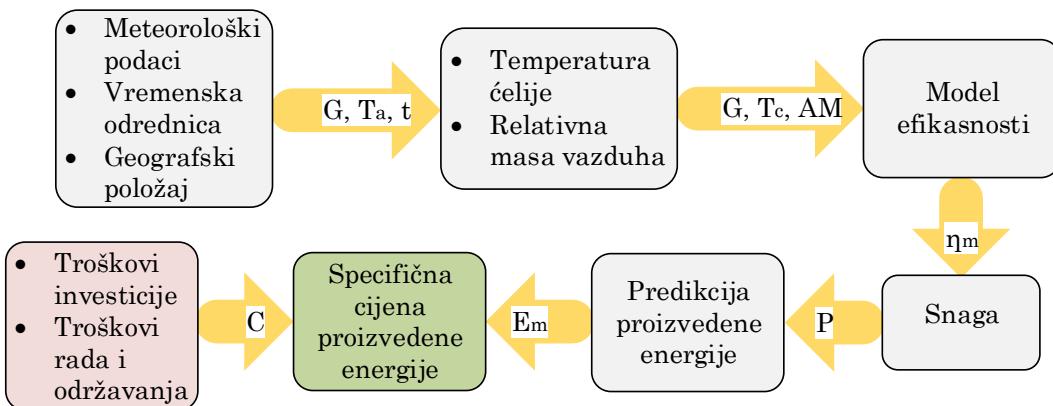
gdje je A aktivna površina panela [m^2]. Takođe, moguće je izvršiti predikciju proizvedene energije za željeni vremenski period, prema jednačini:

$$E_m = \int P dt \quad (1.42)$$

Ukoliko se npr. vrši predikcija proizvedene energije za godinu dana, uz poznavanje godišnje cijene proizvedene energije $C[\$]$ moguće je odrediti specifičnu cijenu proizvedene energije $c[\$/\text{kWh}]$:

$$c = \frac{C}{E_m}. \quad (1.43)$$

Objašnjeni proces predikcije proizvedene energije i specifične cijene njene proizvodnje se može predstaviti dijagramom prikazanim na slici 1.28 [36].



Slika 1.28: Metod za predikciju dnevne, mjesecne i godišnje proizvedene energije, kao i specifične cijene njene proizvodnje

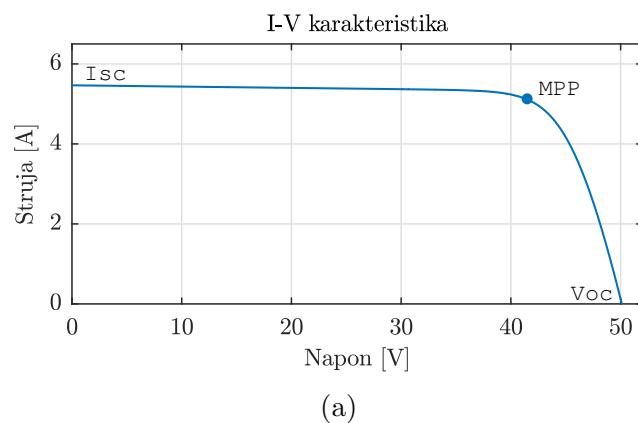
Glava 2

Algoritmi za praćenje tačke maksimalne snage

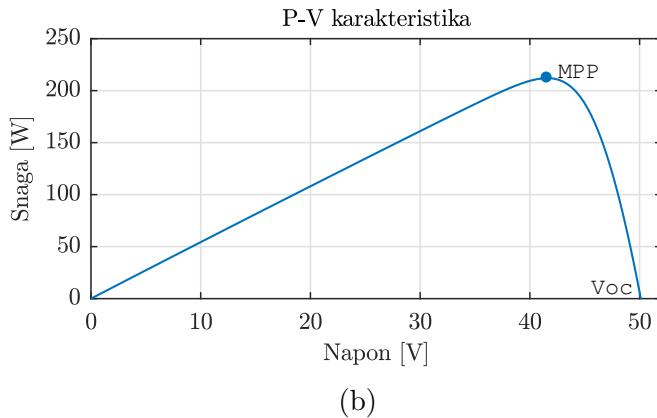
Kao što je navedeno u uvodu rada, efikasnost fotonaponskog sistema je prilično niska. Ona je uslovljena gubicima u samoj solarnoj ćeliji i energetskom pretvaraču koji se javljaju zbog tehnologije ovih elemenata, te se na njih ne može uticati. S druge strane, efikasnost sistema je uslovljena i gubicima koji se javljaju uslijed spoljašnjih klimatskih promjena – solarne iradijanse i temperature. Uticaj ovih gubitaka se može umanjiti upotrebom algoritama za praćenje tačke maksimalne snage, tj. MPPT (eng. *Maximum Power Point Tracking*) algoritama, o čemu će biti više riječi u nastavku.

2.1 Faktor popunjenoosti. Efikasnost fotonaponske ćelije

Na slikama 2.1a i 2.1b su prikazane važne tačke I - V i P - V karakteristike solarne ćelije: I_{sc} i V_{oc} predstavljaju struju kratkog spoja i napon praznog hoda, respektivno, dok MPP (eng. *Maximum Power Point*) predstavlja tačku maksimalne snage.



(a)



Slika 2.1: Značajne tačke I - V i P - V karakteristike solarne čelije

Tačka maksimalne snage je definisana maksimalnom vrijednošću napona V_{mpp} i maksimalnom vrijednošću struje I_{mpp} . U teoriji važi $V_{mpp} = V_{oc}$ i $I_{mpp} = I_{sc}$, što je u praktičnim scenarijima nemoguće postići. Prema tome, mjerama kojom se određuje odnos realne maksimalne snage pri datim vremenskim uslovima ($I_{mpp} \cdot V_{mpp}$) i teorijske maksimalne snage ($I_{sc} \cdot V_{oc}$) se naziva faktor popunjenoosti (eng. *Fill Factor*). Faktor popunjenoosti solarne čelije uglavnom ima vrijednost od 0.7 do 0.9, a definiše se na sljedeći način:

$$FF = \frac{I_{mpp} \cdot V_{mpp}}{I_{sc} \cdot V_{oc}} \quad (2.1)$$

Na osnovu faktora popunjenoosti, moguće je definisati efikasnost (stepen korisnog dejstva) solarne čelije, koja predstavlja odnos proizvedene i ulazne snage solarne čelije:

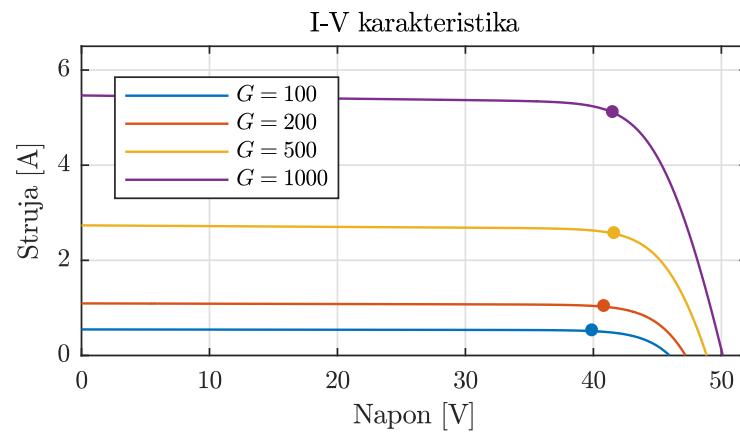
$$\eta = \frac{P_{out}}{P_{in}} = \frac{I_{mpp} \cdot V_{mpp}}{G \cdot S} = \frac{FF \cdot I_{sc} \cdot V_{oc}}{G \cdot S}, \quad (2.2)$$

gdje je G vrijednost solarne iradijanse kojom je ozračena površina čelije S [13, 50].

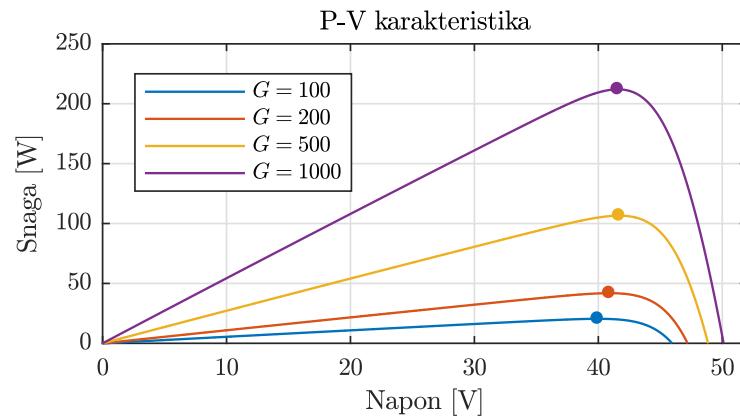
2.2 Uticaj solarne iradijanse i temperature

Solarna iradijansa i temperatura se mijenjaju tokom vremena, te samim tim direktno utiču na proizvodnju električne energije fotonaponske čelije. Iz tog razloga, važno je posmatrati njihov uticaj na I - V i P - V karakteristike čelije, te na položaj tačke maksimalne snage u datim uslovima. Jednačine (1.18),(1.19),(1.20),(1.21) i (1.22) iz prethodnog poglavlja opisuju direktnu zavisnost između parametara solarne čelije/panela I_{ph} , I_s , R_p , R_s i n , i solarne iradijanse G i temperature T .

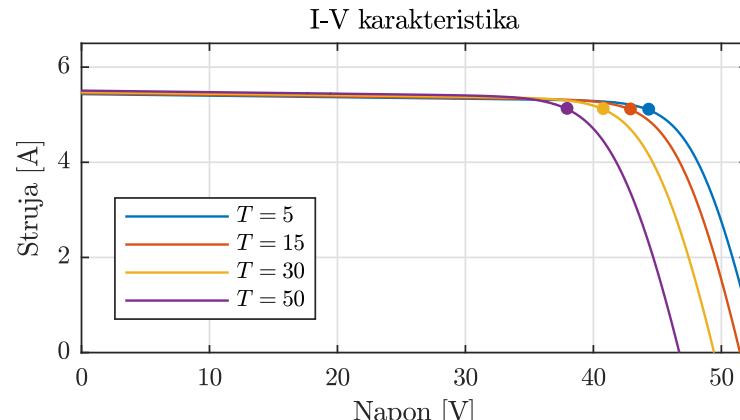
Na slikama 2.2a i 2.2b su prikazane I - V i P - V karakteristike za različite vrijednosti iradijanse pri konstantnoj temperaturi. Može se primijetiti da se sa povećanjem iradijanse cijela karakteristika, a time i tačka maksimalne snage, pomiču prema gore, odnosno da povećanje iradijanse utiče na veću proizvodnju izlazne snage. S druge strane, slike 2.2c i 2.2d pokazuju I - V i P - V karakteristike za različite vrijednosti temperature pri konstantnoj iradijansi, gdje se jasno može vidjeti da se sa povećanjem temperature ove karakteristike i tačka maksimalne snage pomjeraju ulijevo, tj. da sa povećanjem temperature dolazi do opadanja proizvedene snage [13].



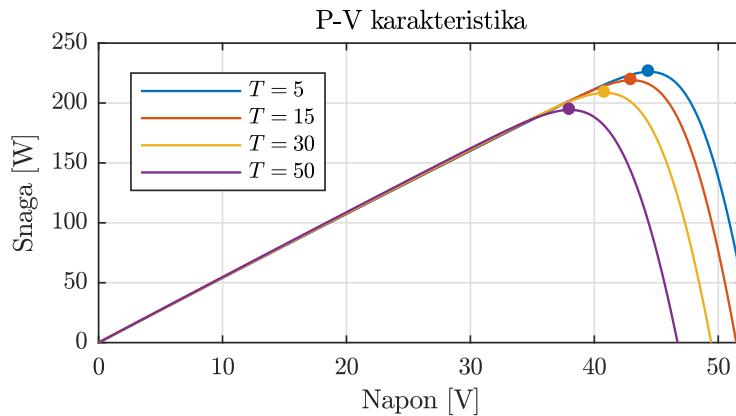
(a) I - V karakteristika za različite vrijednosti solarne iradijanse



(b) P - V karakteristika za različite vrijednosti solarne iradijanse



(c) I - V karakteristika za različite vrijednosti temperature

(d) P - V karakteristika za različite vrijednosti temperature

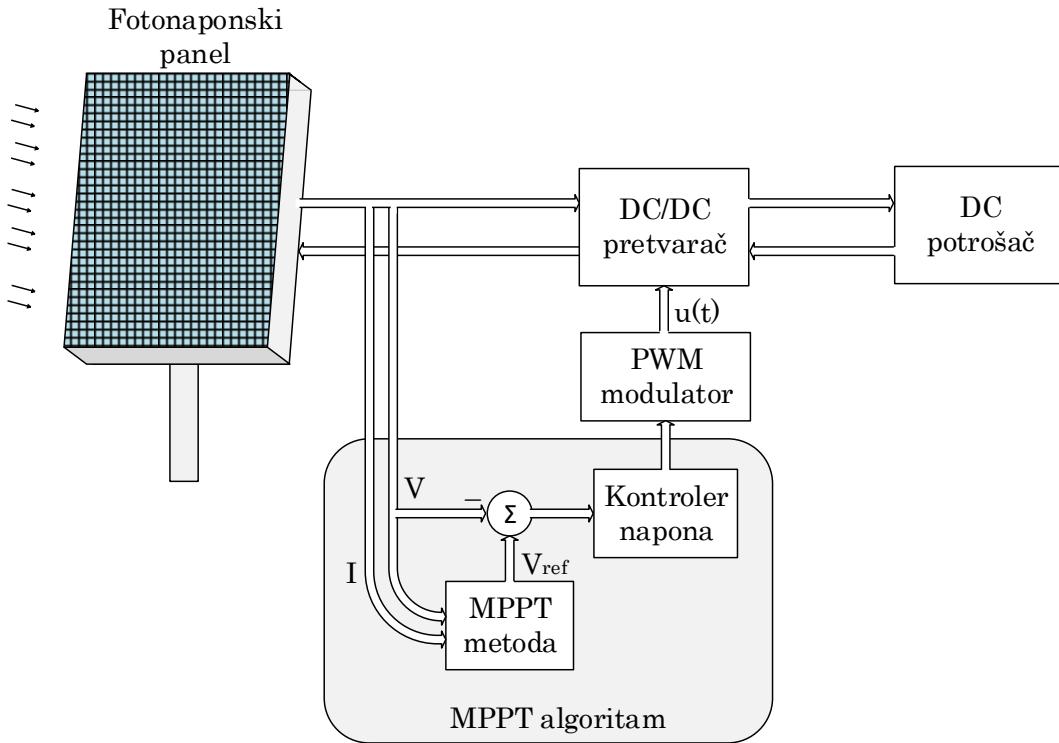
Slika 2.2: I - V i P - V karakteristike za različite vrijednosti solarne iradijanse i temperature

2.3 Formulacija i implementacija MPPT algoritma

Dakle, zaključeno je da tačka maksimalne snage (V_{mpp} , I_{mpp}) varira zavisno od promjene solarne iradijanse i temperature. Pri tome, dovođenje trenutne radne tačke u položaj koji odgovara tački (V_{mpp} , I_{mpp}) omogućava proizvodnju maksimalne snage, a izvršava se primjenom algoritama za praćenje tačke maksimalne snage (MPPT algoritmi). Međutim, ukoliko se ne izvrši primjena ovih algoritama, radna tačka će uvijek biti pozicionirana na istom naponskom nivou, manje ili više udaljena od vrijednosti naponskog nivoa koji odgovara tački maksimalne snage. Važno je naglasiti da će se u nastavku koristiti pojam *solarnog panela* umjesto *solarne ćelije*, s obzirom na to da je riječ o realnim primjenama gdje se ćelija rijetko može naći kao samostalna cjelina.

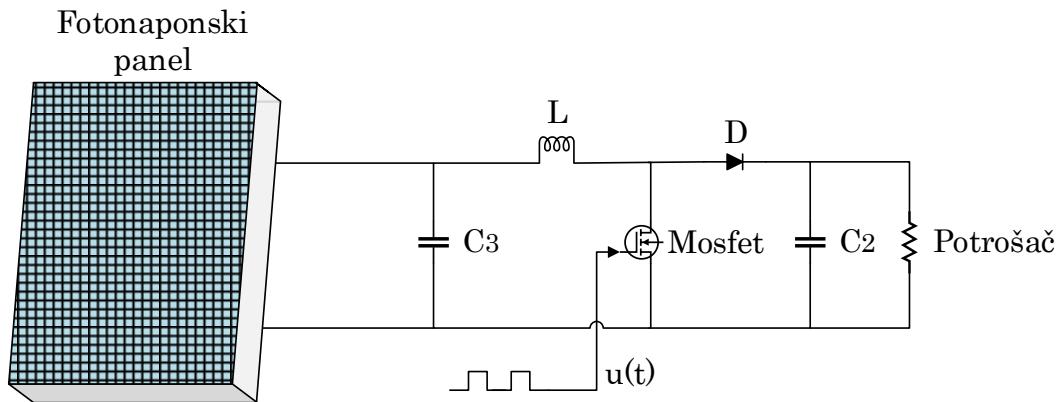
U osnovi, fotonaponski sistem se sastoji od fotonaponskog panela, energetskih pretvarača i potrošača/mreže. Pri tome, fotonaponski panel generiše jednosmjernu struju koju prosljeđuje ili direktno u jednosmjerni potrošač, ili u energetski DC/AC pretvarač – invertor, gdje se vrši konverzija jednosmjerne u naizmjeničnu struju, nakon čega se struja odvodi u mrežu ili u naizmjenični potrošač. MPPT algoritam se implementira u jednosmjernom DC/DC pretvaraču napona – čoperu, koji predstavlja sastavni dio energetskog pretvarača, a u sistemu se nalazi prije invertora. U praksi, najčešće upotrebljivani čoperi su *Boost* čoper i *Buck-Boost* čoper. Na slici 2.3 je prikazana šema opisanog fotonaponskog sistema sa jednosmjernim potrošačem.

MPPT algoritam mjeri izlaznu struju I i izlazni napon V solarnog panela, i određuje referentnu vrijednost napona, tako da važi $V_{ref} = V_{mpp}$. Proporcionalno-integralni (PI) kontroler upoređuje vrijednosti napona V i V_{ref} , i minimizuje razliku između njih $\Delta V = V_{ref} - V$. Konačno, PWM modulator generiše signal $u(t)$ kojim se kontrolišu prekidački elementi čopera [51].



Slika 2.3: Prikaz fotonaponskog sistema [12]

U nastavku je opisan princip funkcionisanja MPPT algoritma uz primjenu Boost čopera (slika 2.4).



Slika 2.4: Šema Boost čopera [12]

Boost čoper se definiše jednačinom:

$$V = V_o(1 - D), \quad (2.3)$$

gdje V predstavlja izlazni napon solarnog panela, V_o izlazni napon Boost čopera, a D faktor popunjenoštvi. Pri tome, MPPT algoritam određuje vrijednost faktora popunjenoštvi D , u skladu sa kojim se generiše PWM signal u PWM modulatoru, a

pomoću kojeg se dalje upravlja prekidačem Boost čopera u cilju maksimizacije izlazne snage fotonaponskog sistema. Na ovaj način se u svakom trenutku vrši promjena faktora popunjenoosti za ΔD , odnosno promjena vrijednosti napona za ΔV [52].

Tokom vremena su razvijene različite vrste MPPT algoritama, koji se razlikuju po kompleksnosti, brzini konvergencije, preciznosti, cijeni potrebnoj za njihovu implementaciju, itd. Oni se mogu klasifikovati na različite načine, pri čemu će u ovom radu biti usvojena podjela na metode koje nisu bazirane na PV modelu (u daljem tekstu: *model-free* metode) i one koje zahtijevaju poznavanje PV modela (u daljem tekstu: *model-based* metode). Model-free metode se mogu definisati samo na osnovu izlazne struje i izlaznog napona solarnog panela, bez neophodnih informacija o PV modelu. Implementacija ovih metoda je jeftina; međutim, one imaju značajne nedostatke, kao što su oscilacije oko tačke maksimalne snage, mala brzina konvergencije i loše performanse pri naglim promjenama vremenskih uslova. Najznačajnije model-free metode su metoda pomjeraja i posmatranja (eng. *Perturb and Observe* – P&O) [53, 54, 55, 56] i metoda inkrementalne konduktanse (eng. *Incremental Conductance* – IC) [52, 57], koje pripadaju grupi *Hill Climbing* algoritama. S druge strane, za razvoj model-based metoda su potrebne informacije o PV modelu. Ove metode se karakterišu brzim odzivom na česte promjene vremenskih uslova i visokom efikasnošću u stacionarnom stanju. Ipak, one zahtijevaju upotrebu senzora za iradijansu, koji su dosta skupi i nepouzdani. Ovaj problem može biti prevaziđen implementacijom algoritma za estimaciju iradijanse [22, 58, 59, 60]. Najznačajniji predstavnici model-based metoda su *soft computing* tehnike: neuralne mreže (eng. *Neural Network*) [9, 61, 62], fazi logika (eng. *Fuzzy Logic*) [63, 64], adaptivni neurofazi sistemi (eng. *Adaptive Neuro-Fuzzy Systems* – ANFIS) [58]. Takođe, ove metode podrazumijevaju i pristupe gdje je PV model određen pomoću ekvivalentnog električnog kola [59].

U nastavku će biti dat pregled najčešće korišćenih MPPT algoritama, sa osvrtom na njihove prednosti i mane.

2.4 Algoritam pomjeraja i posmatranja (eng. *Perturb and Observe* – P&O)

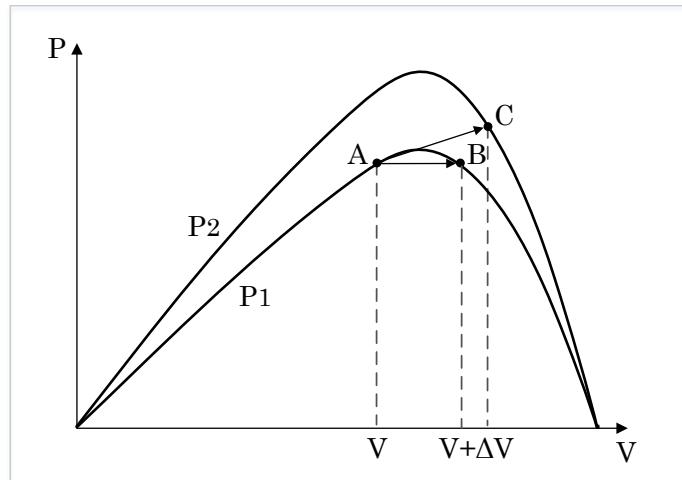
P&O algoritam se zasniva na principu pomjeraja, odnosno perturbacije, radnog napona fotonaponskog panela V , sa ciljem da radna tačka karakteristike panela dostigne vrijednost tačke maksimalne snage MPP. Konkretno, najprije se vrši prepođešavanje faktora popunjenoosti energetskog pretvarača D , čime dolazi do perturbacije izlazne struje panela I , što na kraju uslovljava perturbaciju izlaznog napona panela. Sa slike 2.1 se može vidjeti da povećanje/smanjenje napona povećava/smanjuje snagu kada se radna tačka nalazi sa lijeve strane od MPP, odnosno smanjuje/povećava snagu kada se radna tačka sa desne strane od MPP. Prema tome, ukoliko se snaga uvećava, predznak sljedeće perturbacije napona ΔV treba da ostane nepromijenjen kako bi se dostigla MPP, a ukoliko se snaga smanjuje, predznak sljedeće perturbacije napona se mijenja. Opisani proces (tabela 2.1) se periodično ponavlja dok se ne dostigne vrijednost približna tački maksimalne snage, kada sistem počinje da osciluje oko nje [65]. Pri tome, oscilacije se mogu minimizovati smanjenjem vrijednosti koraka perturbacije; s druge strane, manji korak perturbacije usporava cijeli

MPPT proces. Rješenje ovog problema predstavlja upotreba varijabilnog perturbacionog koraka, čija se vrijednost umanjuje približavanjem tački maksimalne snage. P&O algoritam koji se zasniva na varijabilnom perturbacionom koraku će biti opisan u nastavku.

ΔV	ΔP	Sljedeća perturbacija
+	+	+
+	-	-
-	+	-
-	-	+

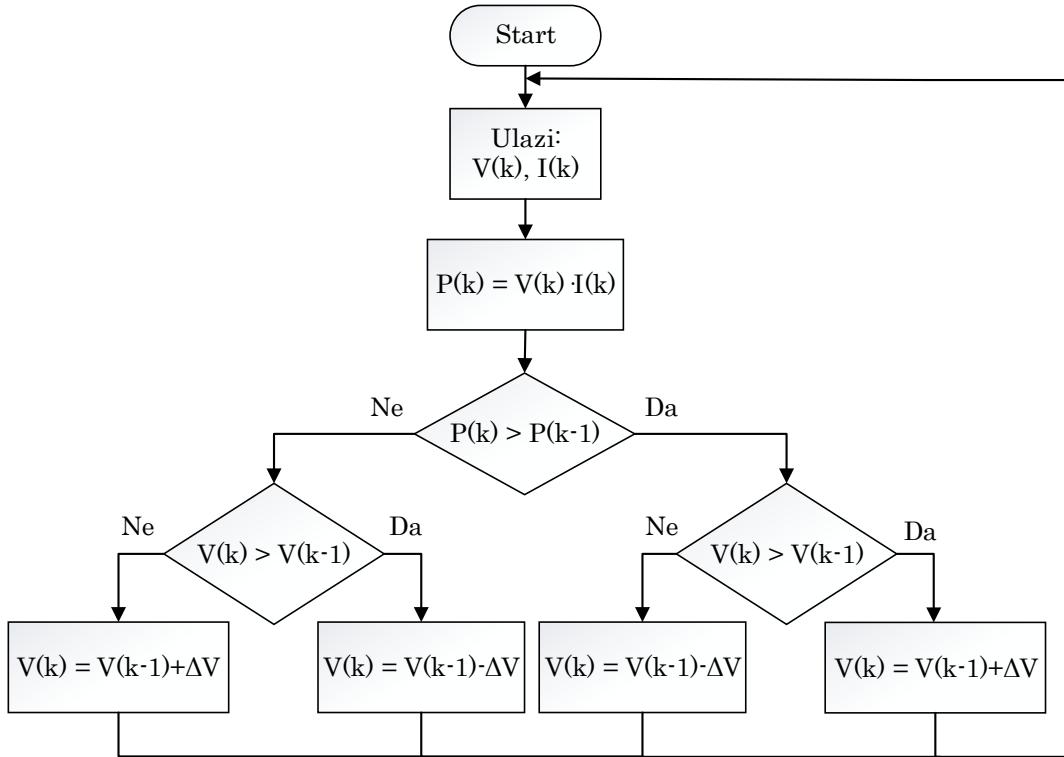
Tabela 2.1: Tabelarni prikaz P&O algoritma

Glavni problem P&O algoritama se javlja u slučaju nagle promjene atmosferskih uslova. Neka je početna tačka – tačka A na krivoj P_1 , koja se nalazi veoma blizu MPP. Tada, ukoliko atmosferski uslovi ostanu nepromijenjeni, perturbacija izlaznog napona panela ΔV će zadržati pozitivan predznak (prethodno su i snaga i napon bili uvećani), te dovesti radnu tačku na poziciju B koja i dalje blago odstupa od MPP. Međutim, ukoliko se iradijansa poveća, doći će do povećanja snage, predznak perturbacije će ostati pozitivan, a radna tačka će preći u poziciju C čime se značajno udaljava od MPP. Pri tome, ako se iradijansa bude dalje uvećavala, radna tačka će se dodatno udaljavati od MPP. Ova pojava se naziva klizanje radne tačke, a prikazana je slikom 2.5 [65].



Slika 2.5: Primjer klizanja radne tačke [12]

Šematski prikaz P&O algoritma je dat na slici 2.6:



Slika 2.6: Šematski prikaz P&O algoritma [12]

2.4.1 P&O algoritam sa varijabilnim perturbacionim korakom

Kao što je prethodno naglašeno, konvencionalni P&O algoritam sa fiksnim perturbacionim korakom zahtijeva definisanje optimalne vrijednosti koraka. Cilj je odrabiti vrijednost koja nije previše velika, kako ne bi došlo do većih promjena napona i time većih oscilacija u stacionarnom stanju; s druge strane, mala vrijednost može značajno da uspori proces pronalaženja tačke MPP. Navedeni problem se rješava upotrebom varijabilnog perturbacionog koraka. Pri tome, potrebno je voditi računa da algoritam ima mogućnost praćenja tačke maksimalne snage čak i u slučaju nagle promjene solarne iradijanse. Rješenja predložena u literaturi [66, 67, 68] pokazuju nedostatke upravo u tim situacijama, kada pri nagnom povećanju iradijanse dođe do značajnog povećanja snage, dok promjena napona ostane mala.

U cilju prevazilaženja ovog problema, u [69] je opisan P&O algoritam koji se bazira na varijabilnom koraku promjene napona. On se sastoji iz dva člana: prvi član sadrži faktor zaboravljanja β , kojim algoritam zaboravlja određeni dio vrijednosti varijabilnog koraka iz prethodne iteracije $\Delta V(k)$; drugi član se koristi kod većine algoritama sa varijabilnim perturbacionim korakom, a predstavlja absolutni odnos promjene snage $\Delta P(k)$ i promjene napona $\Delta V(k)$ skaliran konstantnom γ . Tada, varijabilni korak napona $\Delta V(k+1)$, definisan navedenim algoritmom, dobija sljedeći oblik:

$$\Delta V(k+1) = \beta \Delta V(k) + \gamma \left| \frac{\Delta P(k)}{\Delta V(k)} \right|. \quad (2.4)$$

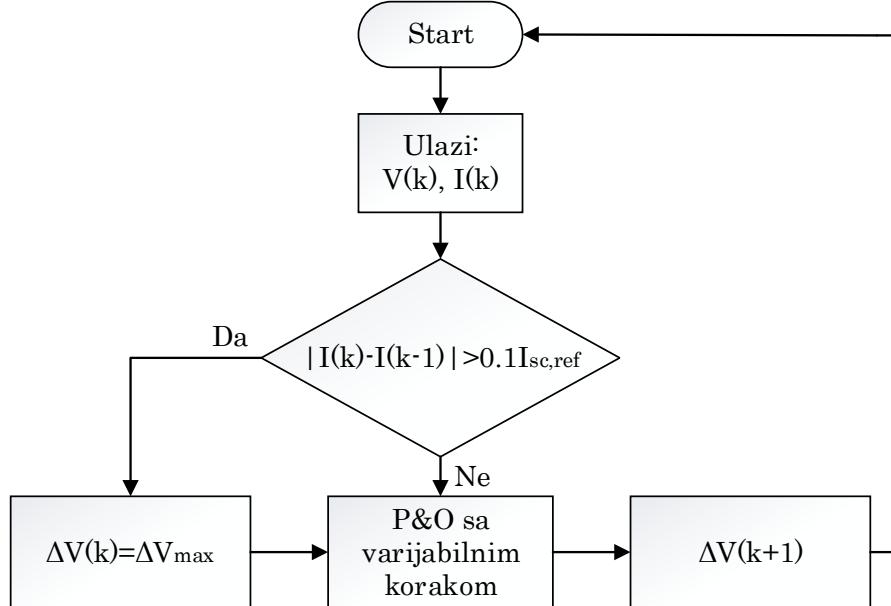
Pri tome, faktor zaboravljanja se proizvoljno određuje iz opsega $\{0, 1\}$, čime se za estimaciju novih podataka uzima u obzir samo određeni procenat prethodnog varijabilnog koraka. S druge strane, konstanta γ sprječava dostizanje previše velike vrijednosti odnosa $\Delta P(k)/\Delta V(k)$, a definiše se eksperimentalno, kao u radovima [66, 67].

Ovaj algoritam, takođe, omogućava detekciju promjene solarne iradijanse uvođenjem uslova baziranog na aproksimaciji da je struja proporcionalna iradijansi, odnosno da svaka promjena iradijanse izaziva proporcionalnu promjenu struje:

$$|I(k) - I(k-1)| > 0.1 I_{sc,ref}, \quad (2.5)$$

gdje su $I(k)$ i $I(k-1)$ vrijednosti struje u trenutnoj i prethodnoj iteraciji, respektivno, dok je $I_{sc,ref}$ struja kratkog spoja mjerena pri iradijansi 1000 W/m^2 . Tada, ukoliko dođe do promjene iradijanse veće od 100 W/m^2 , izvršiće se prepodešavanje koraka napona, odnosno njegovo postavljanje na višu, fiksnu vrijednost u cilju bržeg dostizanja željenog stanja.

Šematski prikaz opisanog P&O algoritma sa varijabilnim perturbacionim korakom napona je dat na sljedećoj slici:



Slika 2.7: Šematski prikaz P&O algoritma sa varijabilnim perturbacionim korakom napona

Rezultati poređenja opisanog algoritma i drugih MPPT tehnika su prikazani u četvrtom poglavljju.

2.5 Algoritam inkrementalne konduktanse (eng. *Incremental Conductance – IC*)

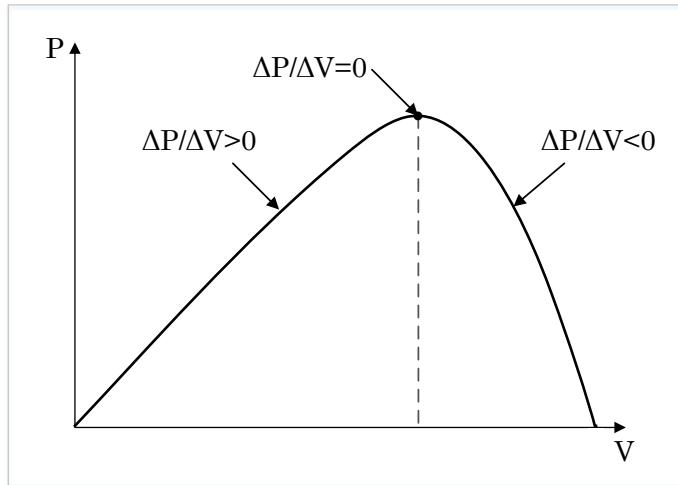
Algoritam inkrementalne konduktanse se zasniva na praćenju nagiba P - V krive panela, pri čemu važe uslovi:

$$\frac{\partial P}{\partial V} = 0 \text{ -- u tački MPP,} \quad (2.6a)$$

$$\frac{\partial P}{\partial V} > 0 \text{ -- lijevo od MPP,} \quad (2.6b)$$

$$\frac{\partial P}{\partial V} < 0 \text{ -- desno od MPP,} \quad (2.6c)$$

koji su predstavljeni slikom 2.8:



Slika 2.8: Prikaz uslova algoritma inkrementalne konduktanse na P - V krivoj

Tada, ukoliko se odnos $\frac{\partial P}{\partial V}$ zapiše kao:

$$\frac{\partial P}{\partial V} = \frac{\partial(V \cdot I)}{\partial V} = I + \frac{\partial I}{\partial V} \approx I + V \frac{\partial I}{\partial V}, \quad (2.7)$$

moguće je definisati uslove algoritma u sljedećem obliku:

$$\frac{\Delta I}{\Delta V} = \frac{-I}{V} \text{ -- u tački MPP,} \quad (2.8a)$$

$$\frac{\Delta I}{\Delta V} > \frac{-I}{V} \text{ -- lijevo od MPP,} \quad (2.8b)$$

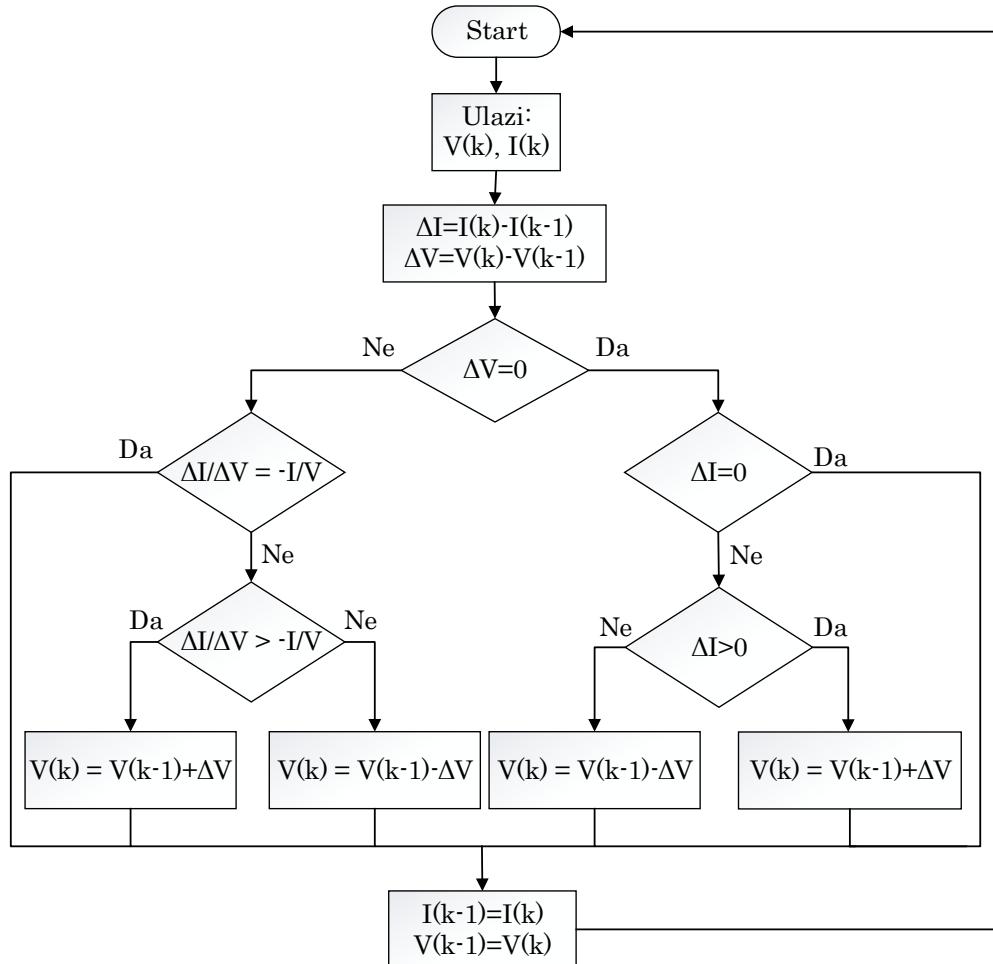
$$\frac{\Delta I}{\Delta V} < \frac{-I}{V} \text{ -- desno od MPP.} \quad (2.8c)$$

Prema tome, tačka maksimalne snage se može pratiti poređenjem trenutne konduktanse I/V sa inkrementalnom konduktansom $\Delta I/\Delta V$, na osnovu čega se definiše predznak perturbacije napona ΔV [52].

Glavna prednost predstavljenog IC algoritma u odnosu na P&O algoritam je to što on ima mogućnost određivanja tačnog smjera kretanja radne tačke ka tački MPP, zbog čega se značajno umanjuju oscilacije u stacionarnom stanju i poboljšava praćenje MPP pri nagloj promjeni vremenskih uslova. Takođe, kada radna tačka dostigne poziciju MPP, algoritam to registruje i ne pomjera je dok ne dođe do promjene vremenskih uslova [70, 71]. S druge strane, IC algoritam se karakteriše visokom računskom kompleksnošću, što se smatra njegovim osnovnim nedostatkom.

Opisani IC algoritam koristi fiksani korak perturbacije napona. Pri tome, mala vrijednost koraka usporava izvršenje algoritma, dok njegova veća vrijednost povećava oscilacije oko MPP. Ovaj problem se može riješiti primjenom varijabilnog koraka perturbacije, koji se smanjuje kako se radna tačka približava MPP, te na taj način obezbeđuje zadovoljavajuću tačnost u praćenju tačke MPP, kao i brzinu konvergencije [72].

Šematski prikaz algoritma inkrementalne konduktanse je dat na slici 2.9 [52].



2.6 Model-based MPPT algoritam baziran na ekvivalentnom električnom kolu panela

Za razliku od prethodno opisanih model-free MPPT algoritama, u nastavku je prikazan model-based MPPT algoritam koji je baziran na jednodiodnom ekvivalentnom električnom kolu panela (EMPPT algoritam) [59]. Pri tome, razmotrena su dva moguća slučaja. U prvom slučaju se vrijednosti solarne iradijanse G i temperature T smatraju dostupnim, dok je u drugom slučaju vrijednost temperature T poznata, a vrijednost iradijanse G nepoznata. Iz tog razloga, definisan je estimator iradijanse EEST, koji je baziran na izlaznoj struji i izlaznom naponu panela.

2.6.1 Slučaj poznate solarne iradijanse

PV model je određen jednačinom (1.11) koja je zadata u implicitnom obliku. U cilju definisanja eksplicitne zavisnosti I od V , moguće je primijeniti Lambertovu W funkciju, tako da $I-V$ karakteristika dobije sljedeći oblik:

$$I = f(V) = -\frac{V}{R_s + R_p} - \frac{W(g(V))V_t}{R_s} + \frac{R_p(I_s + I_{ph})}{R_s + R_p}. \quad (2.9)$$

Pri tome, Lambertova funkcija W se definiše izrazom:

$$W(x) \cdot \exp(W(x)) = x, \quad (2.10)$$

što je detaljnije opisano u [73], dok je nelinearna funkcija $g(V)$ predstavljena jednačinom:

$$g(V) = \frac{R_s I_s R_p \exp\left(\frac{R_p(R_s I_{ph} + R_s I_s + V)}{V_t(R_s + R_p)}\right)}{V_t(R_s + R_p)}. \quad (2.11)$$

Prema tome, izlazna snaga solarnog panela se može zapisati kao:

$$P = V \cdot I = V \cdot f(V) = \Theta(V). \quad (2.12)$$

Kako je $P = \Theta(V)$ konkavna funkcija snage zavisne od napona, jednačina (2.12) se može posmatrati kao cost funkcija koju je potrebno maksimizovati određivanjem odgovarajuće vrijednosti napona $V_{mpp} = V^*$. U tu svrhu se može primijeniti gradijentni metod, tako da važi:

$$\frac{\partial P}{\partial V} = \frac{\partial \Theta(V)}{\partial V} = I + V \frac{\partial I}{\partial V} = f(V) + V \frac{\partial f(V)}{\partial V}. \quad (2.13)$$

Daljim izvođenjem, koje je prikazano u literaturi [59], definiše se gradijentno pravilo promjene napona:

$$\hat{V} = k_g \frac{\partial \Theta(V)}{\partial V} = f(V) - V \left(\frac{1}{R_s + R_p} + \frac{V_t}{R_s} g_1(V) g_2(V) \right), \quad (2.14)$$

gdje je $k_g > 0$ pojačanje, $g_1(V) = \partial W / \partial g$, a $g_2(V) = \partial g(V) / \partial V$. Kao što se može primijetiti, gradijentno pravilo prikazano jednačinom (2.14) sadrži Lambertovu W funkciju u sklopu funkcija $f(V)$ i $g_1(V)$. Radi lakše implementacije ovog metoda,

moguće je izvršiti aproksimaciju Lambertove funkcije za $W(g(V)) > 0, \forall V \in [0, V_{oc}]$, na sljedeći način:

$$W(x) = (1 + \epsilon) \ln \left(\frac{\frac{6}{5}x}{\ln \left(\frac{\frac{12}{5}x}{\ln(1 + \frac{12}{5}x)} \right)} \right) - \epsilon \ln \left(\frac{2x}{\ln(1 + 2x)} \right), \quad (2.15)$$

gdje je $\epsilon = 0.4586887$ [74].

2.6.2 Slučaj nepoznate solarne iradijanse

Mjerenje solarne iradijanse zahtijeva upotrebu prilično skupih senzora (piranometara), zbog čega se često pribjegava njenoj estimaciji. U [59] je definisan estimator iradijanse (EEST) pomoću izmjerena vrijednosti izlazne struje i izlaznog napona panela:

$$G = G_{ref} \left(\frac{I_{sc,ref} + \Delta I}{I_{sc,ref} - \frac{\alpha}{\beta} (R_s \Delta I + \Delta V)} \right), \quad (2.16)$$

gdje su α i β temperaturni koeficijenti kratkog spoja i praznog hoda panela, respektivno, koji su dati u katalogu panela, dok su G_{ref} i $I_{sc,ref}$ vrijednosti solarne iradijanse i struje kratkog spoja pri standardnim testnim uslovima. Promjene izlazne struje i izlaznog napona uslijed promjena u atmosferskim uslovima se određuju na osnovu jednačina:

$$\Delta I = I_n - I_{ref}, \quad (2.17)$$

$$\Delta V = V_n - V_{ref}, \quad (2.18)$$

gdje su I_n i V_n izmjerene vrijednosti izlazne struje i izlaznog napona panela u realnim radnim uslovima, dok su I_{ref} i V_{ref} vrijednosti izlazne struje i izlaznog napona panela pri standardnim testnim uslovima.

Nakon estimacije iradijanse G , moguće je odrediti pet parametara panela na osnovu jednačina (1.18),(1.19),(1.20),(1.21) i (1.22) iz prethodnog poglavljja. Na kraju, proračunava se optimalna vrijednost napona V_{mpp} primjenom gradijentnog pravila (2.14), gdje je Lambertova funkcija određena izrazom (2.15).

U četvrtom poglavljju su dati rezultati poređenja opisanog EMPPT algoritma uz upotrebu EEST estimatora iradijanse, sa drugim MPPT tehnikama.

Glava 3

MPPT algoritmi zasnovani na neuralnim mrežama

U prethodnom poglavlju su opisani najčešće korišćeni MPPT model-free algoritmi, kao i model-based algoritam koji je baziran na ekvivalentnom električnom kolu panela. Većina ostalih model-based MPPT algoritama je razvijeno upotrebom soft-computing tehnika (neuralne mreže, fazi logika, itd.), kao što je slučaj i sa MPPT algoritmom predloženim u ovom radu. Iz tog razloga, u ovom poglavlju je najprije dat opis arhitekture neuralne mreže (eng. *Neural Network* – NN) i princip njenog rada, nakon čega je predstavljen postupak identifikacije modela fotonaponskog panela pomoću neuralnih mreža (NN model), kao i kratak pregled MPPT algoritama baziranih na neuralnim mrežama (NN-based MPPT algoritmi). Na kraju, opisan je predloženi MPPT algoritam razvijen na osnovu NN modela (NMPPT algoritam), a, takođe, je dat i predlog algoritma za estimaciju iradijanse na bazi tog NN modela.

3.1 Arhitektura i princip rada neuralne mreže

Neuralne mreže predstavljaju tehniku koja danas ima široku primjenu u rješavanju kompleksnih problema iz različitih oblasti, kao što su: prepoznavanje obrazaca (eng. *Pattern Recognition*), modelovanje, identifikacija, klasifikacija, predikcija, upravljanje sistemima [20, 75, 76, 77].

U zavisnosti od primjene neuralne mreže, njene funkcije i zahtijevane tačnosti rezultata, koriste se različite arhitekture mreže. U opštem slučaju, neuralna mreža se sastoji od ulaznog sloja, jednog ili više skrivenih slojeva, i izlaznog sloja. Ulazni sloj prima ulazne podatke, oni se pojedinačno množe težinskim koeficijentima, a zatim se dobijene vrijednosti sumiraju u neuronima skrivenog sloja. Ta suma se dalje prosljeđuje aktivacionim funkcijama koje limitiraju izlazni signal neurona [20, 75]. Prema Teoremi o univerzalnoj aproksimaciji, standardna višeslojna Feedforward neuralna mreža, koja se sastoji od jednog skrivenog sloja i proizvoljne aktivacione funkcije, smatra se univerzalnim aproksimatom (sposobnost mreže da aproksimira različite funkcije). Ova osobina mreže ne zavisi od izbora aktivacione funkcije, već je uslovljena isključivo njenom višeslojnom feedforward arhitekturom. Međutim, potrebno je istaći da navedena tvrdnja ne znači da će svaka aktivaciona funkcija dati jednak dobre rezultate u različitim slučajevima. Takođe, prilikom određivanja arhitekture mreže, treba voditi računa o njenoj kompleksnosti i efikasnosti [78].

Dakle, najprije je potrebno odrediti strukturu neuralne mreže. Nakon toga, vrši se njeni treniranje. Treniranje mreže podrazumijeva podešavanje težinskih koeficijenata i bias-a, u cilju generisanja odgovarajućih izlaznih podataka za odabrani set ulaznih podatka. Upravo iz tog razloga, mrežu je potrebno trenirati za što širi opseg vrijednosti ulaznih i odgovarajućih izlaznih parametara, koji su od interesa u posmatranoj situaciji. Treniranje se vrši upotrebom nekog od optimizacionih algoritama, kao što su gradijentni algoritam (eng. *Gradient Descent*), Levenberg-Marquardt, itd, sa ciljem minimizacije funkcije performanse (cost funkcije). Ova funkcija se najčešće definiše kao srednja kvadratna greška (eng. *Mean Squared Error* – MSE), odnosno kao kvadrat razlike između željenih izlaznih podataka i podataka dobijenih na izlazu neuralne mreže, a definisana je sljedećom jednačinom:

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_{izl} - Y_{ref})^2, \quad (3.1)$$

gdje su Y_{izl} i Y_{ref} stvarna vrijednost tog parametra izmjerena na izlazu i željena vrijednost izlaznog parametra mreže, respektivno, dok je N broj uzoraka za koje se vrši treniranje mreže. Izlaz y_j iz neurona j , na koji je primijenjena aktivaciona funkcija f , se definiše na sljedeći način:

$$y_j = f \left[\left(\sum_i w_{ij} x_i \right) + b_j \right], \quad (3.2)$$

gdje je w_{ij} težinski koeficijent koji se odnosi na ulaz tog neurona x_i , a b_j je bias. U praksi se koriste različiti tipovi aktivacionih funkcija, među kojima su najprisutnije hiperbolični tangens:

$$f(x) = \tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1}, \quad (3.3)$$

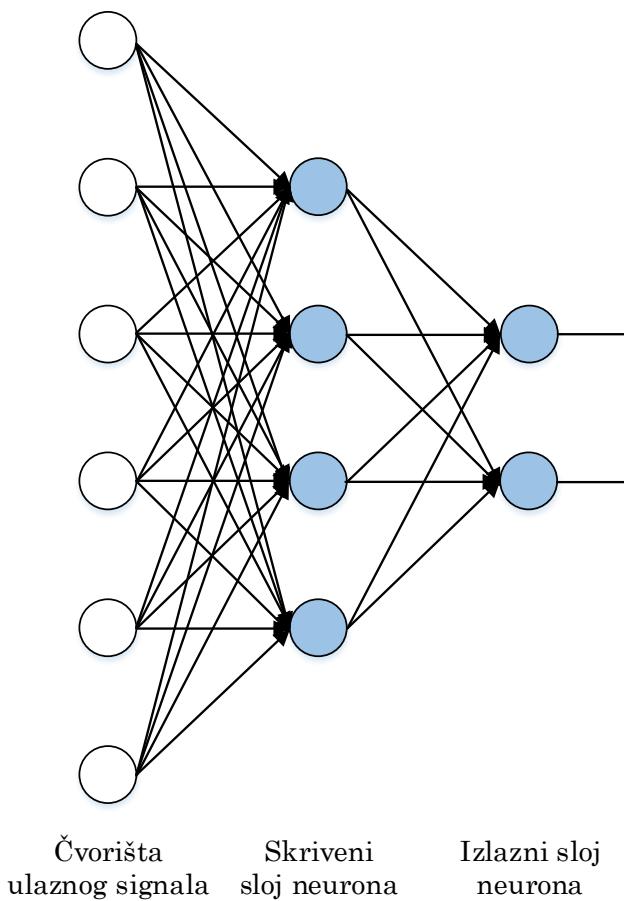
i linearne:

$$f(x) = x. \quad (3.4)$$

Pri tome, hiperbolični tangens se najčešće primjenjuje na izlazu iz skrivenih neurona, kako bi limitirala njihov izlazni signal, dok se linearna aktivaciona funkcija primjenjuje na izlazne signale izlaznog sloja mreže kako bi smanjila kompleksnost krajnjih proračuna [75, 76].

Na kraju, potrebno je izvršiti testiranje mreže, čime se vrši provjera njene tačnosti za vrijednosti ulaznih parametara koje izlaze iz opsega podrazumijevanog pilikom treniranja [75].

Primjer višeslojne Feedforward neuralne mreže sa jednim skrivenim slojem, na kojem se jasno može uočiti opisana arhitektura i princip rada, je prikazan na slici 3.1.

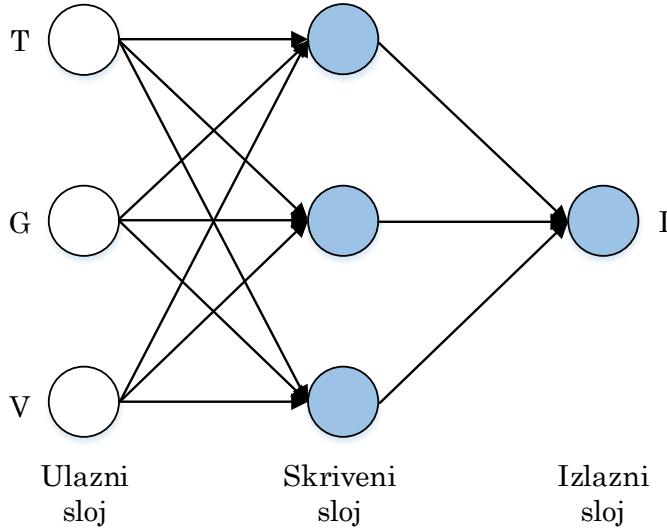


Slika 3.1: Feedforward neuralna mreža sa jednim skrivenim slojem

3.2 Modelovanje fotonaponskog panela pomoću neuralne mreže

U posljednje vrijeme, modelovanje fotonaponskog panela se sve češće vrši uz pomoć neuralnih mreža, pri čemu je u literaturi predložena primjena mreža različitih arhitektura [79, 80, 81, 82, 83, 84]. Takođe, u modelovanju panela se može primijeniti i hibridni pristup, koji kombinuje prednosti neuralnih mreža i fazi logike [85]. U ovoj sekciji je opisano modelovanje panela pomoću veoma jednostavne Feedforward neuralne mreže, zato što će implementacija predloženog MPPT algoritma i estimatora iradijanse biti bazirana na tom modelu.

Odabrana Feedforward neuralna mreža se sastoji od jednog skrivenog sloja i tri skrivena neurona u njemu, kao što je prikazano na slici 3.2.



Slika 3.2: Arhitektura NN modela fotonaponskog panela

Ulagni parametri mreže su solarna iradijansa G , temperatura T i izlagani napon panela V , dok izlagana struja panela I predstavlja izlagni parametar. Pri tome, važno je napomenuti da se temperatura T konkretno odnosi na temperaturu solarne ćelije, odnosno solarnog panela. Dakle, izlagana struja panela se može definisati na sljedeći način:

$$\hat{I} = \text{net}(\mathbf{u}) = f [\mathbf{W}_2 \tanh (\mathbf{W}_1 \mathbf{u} + \mathbf{b}_1) + b_2], \quad (3.5)$$

gdje je $\mathbf{u} = [T \ G \ V]^T$, dok su \mathbf{W}_1 , \mathbf{W}_2 , \mathbf{b}_1 i b_2 težinski i bias koeficijenti, respektivno, koje mreža treba da "nauči" u toku treniranja. Osim toga, $\tanh(\cdot)$ funkcija hiperboličnog tangensa je opisana jednačinom (3.3), a $f(\cdot)$ je linearna aktivaciona funkcija prikazana jednačinom (3.4).

U cilju ubrzavanja procesa treniranja, vrši se normalizacija vrijednosti ulagnih parametara upotrebom sljedećeg pristupa:

$$u_{i,norm} = \frac{u_i - u_{i,\min}}{u_{i,\max} - u_{i,\min}}, \quad i \in \{T, G, V\}, \quad (3.6)$$

gdje indeksi \min i \max označavaju minimalne i maksimalne vrijednosti ulagnih parametara T , G i V iz treniranja seta. Slična operacija može biti izvršena na vrijednostima izlagnog parametra iz treniranja seta.

Koeficijenti neuralne mreže se optimizuju upotrebom Levenberg-Marquardt algoritma ili nekog drugog algoritma drugog reda, zato što se oni smatraju jednim od najbržih algoritama za treniranje manje kompleksnih mreža. Funkcija performanse koja se koristi je definisana kao srednja kvadratna greška između izmjerene i željene vrijednosti struje:

$$J = \frac{1}{\sum_{i=1}^M N_i} \sum_{i=1}^M \sum_{k=1}^{N_i} (\hat{I} - I)^2, \quad (3.7)$$

gdje N_i predstavlja broj tačaka jedne I - V krive za određenu vrijednost iradijanse G_i i temperature T_i , dok M predstavlja ukupan broj I - V krivih iz trening seta.

Tačke I - V krivih koje služe za treniranje mreže se mogu dobiti eksperimentalnim putem, odnosno mjeranjem pod kontrolisanim atmosferskim uslovima [86]. Cilj je odabratи vrijednosti solarne iradijanse i temperature koje su ravnomjerno raspoređene u posmatranom opsegu kako ne bi došlo do pretreniranja (eng. *overfitting*)/podtreniranja (eng. *underfitting*) mreže u intervalima gdje ima previše/premalo trening podataka. Takođe, treba voditi računa da posmatrani opseg vrijednosti G i T obuhvata sve vrijednosti koje se mogu javiti u praktičnim scenarijima, zato što neuralna mreža nema dovoljno dobre sposobnosti ekstrapolacije. U slučaju kada je dostupan mali broj eksperimentalno prikupljenih podataka ili podataka iz proizvodnih kataloga panela, moguće je generisati trening podatke pomoću ekvivalentnog električnog kola panela. Pri tome, najprije je potrebno odrediti parametre kola, nakon čega se trening podaci mogu definisati upotrebom jednačina (1.11), (1.18), (1.19), (1.20), (1.21), (1.22). Ipak, važno je istaći da PV modeli koji su formirani na osnovu mjerenih podataka uglavnom pokazuju veću tačnost od modela baziranih na ekvivalentnom električnom kolu [87].

3.3 Pregled MPPT algoritama baziranih na neuralnim mrežama

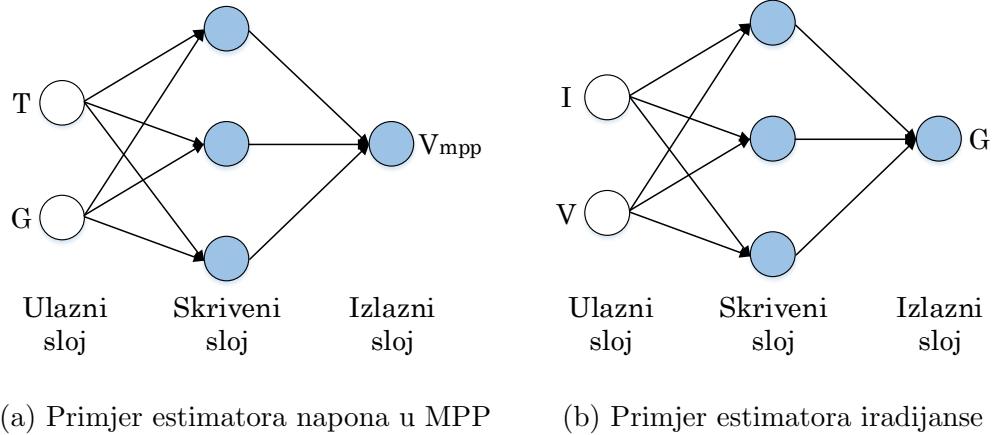
Kao što je prethodno navedeno, mnogi MPPT algoritmi u literaturi su razvijeni na bazi neuralnih mreža (NN-based MPPT algoritmi). Detaljan opis različitih NN-based MPPT algoritama je dat u [9], gdje su predložene njihove dvije klasifikacije: prva klasifikacija je izvršena prema vrsti ulaznih parametara, a druga na osnovu strukture samog NN-based MPPT algoritma. Prema prvoj klasifikaciji, NN-based MPPT algoritmi se dijele na one koji imaju sve električne, sve neelektrične, i kombinaciju električnih i neelektričnih ulaznih parametara. Pri tome, električni ulazni parametri se mogu odnositi na podatke iz proizvodnog kataloga panela ili na izmjerene vrijednosti struje i napona, dok neelektrični ulazni parametri podrazumijevaju solarnu iradijansu i temperaturu.

Kada je riječ o prvoj grupi NN-based MPPT algoritama koja koristi sve električne ulazne parametre, postoje algoritmi koji koriste samo podatke iz proizvodnog kataloga [88], samo izmjerene vrijednosti struje i napona [61], dok se najbolji rezultati ostvaruju kombinacijom električnih parametara iz navedenih grupa, kao što je opisano u [89].

S druge strane, među algoritmima koji koriste neelektrične ulazne parametre najbolje rezultate daju oni koji koriste i G i T da bi odredili napon u tački maksimalne snage V_{mpp} [90, 91, 92]. Primjer Feedforward neuralne mreže na kojem je baziran takav NN-based MMPT algoritam je dat na slici 3.3a. Njegova glavna prednost je to što direktno određuje V_{mpp} , čime je omogućeno dobro praćenje naglih promjena atmosferskih uslova. Ipak, nedostatak ovog algoritma je neophodna informacija o solarnoj iradijansi. Takođe, potrebno je naglasiti da se u istu svrhu mogu koristiti i drugi tipovi neuralnih mreža, kao što su neuralne mreže sa radikalnim aktivacionim funkcijama (eng. *Radial Basis Function Neural Networks*) [93]. Osim toga, u [94]

je predložena kaskadna NN-based MPPT tehnika (CNNMPPT), gdje su korištene dvije neuralne mreže kako bi se odredio V_{mpp} . Pri tome, prva mreža proračunava iradijansu na osnovu izmjerenih vrijednosti napona i struje (slika 3.3b), dok druga mreža određuje V_{mpp} pomoću temperature i izračunate iradijanse (slika 3.3a). Ova tehnika daje dobre rezultate, ali pokazuje nedostatak zbog značajno povećane računske kompleksnosti. Autori u [94] predlažu upotrebu 10 skrivenih neurona u obije mreže. Takođe, u literaturi su prisutna istraživanja gdje se uzima samo solarna iradijansa kao ulazni parametar, zato što ona najviše utiče na proizvedenu snagu panela [95].

Primjeri NN-based MPPT algoritama koji koriste kombinaciju električnih i ne-električnih parametara su dati u radovima [62, 96, 97]. Oni pokazuju veoma dobre performanse, ali je njihova implementacija prilično skupa.



Slika 3.3: Arhitektura neuralnih mreža korištenih za estimaciju V_{mpp} i G

Druga klasifikacija dijeli NN-based MPPT tehnike prema strukturi na samostalne i hibridne. Arhitektura samostalnih algoritama je bazirana isključivo na neuralnoj mreži kao kontroleru za praćenje tačke maksimalne snage [89, 98], dok hibridne tehnike omogućavaju integraciju neuralne mreže sa nekom drugom standardnom ili soft-computing MPPT tehnikom. Kombinacija neuralne mreže sa standardnom MPPT tehnikom (P&O, IC, itd.) nudi dosta bolje performanse [99, 100], dok kombinacija sa drugom soft-computing tehnikom (fazi logika, genetski algoritam, itd.) značajno poboljšava performanse kontrolera, ali na račun povećanja njegove kompleksnosti [101, 102].

3.4 Predlog MPPT algoritma i estimatora iradijanse baziranih na NN modelu panela

U ovom poglavlju je dat predlog MPPT algoritma implementiranog na bazi modela neuralne mreže (NMPPT algoritam), kao i estimatora iradijanse koji dodatno povećava tačnost u predikciji tačke maksimalne snage. Za razliku od dostupnih MPPT algoritama baziranih na neuralnim mrežama koji direktno predviđaju V_{mpp} na osnovu mjerjenja, predloženi algoritam je razvijen upotrebom NN modela solarnog

panela, opisanog u sekciji 3.2. Naime, izraz za izlaznu struju NN modela je upotrijebljen za izvođenje analitičkih iterativnih pravila za određivanje napona u tački maksimalne snage V_{mpp} , kao i za estimaciju iradijanse. Predloženo rješenje se karakteriše izrazito malom računskom kompleksnošću u poređenju sa dostupnim MPPT algoritmima koji koriste iste ulazne parametre. Dok ostala rješenja podrazumijevaju upotrebu jedne višeslojne ili dvije jednoslojne neuralne mreže, implementirana MPPT tehnika se bazira na jednoslojnem NN modelu koji se sastoji od samo 4 skrivena neurona, a pokazuje visoku tačnost. Ova tehnika ne može trenutno predvidjeti napon V_{mpp} , ali sadrži parametar čijim podešavanjem se može ostvariti željeni balans između brzine praćenja tačke MPP i računske kompleksnosti.

3.4.1 NMPPT algoritam

Relacija između izlazne snage, izlazne struje i izlaznog napona solarnog panela je opisana izrazom:

$$P = V \cdot I = V \cdot I(T, G, V). \quad (3.8)$$

Kao što je prethodno navedeno, cilj MPPT algoritma je da detektuje tačku (V_{mpp}, I_{mpp}) u kojoj izlazna snaga P ima maksimalnu vrijednost:

$$P_{mpp} = P(V_{mpp}, I_{mpp}) \geq P(V, I), \forall V, I. \quad (3.9)$$

Poznato je da $P-V$ kriva ima konkavni oblik za vrijeme konstantne iradijanse (slika 2.1). Prema tome, za definisanje tačke maksimalne snage MPP, može se upotrijebiti metoda rastućeg gradijenta (eng. *Gradient Ascend*):

$$V_{k+1} = V_k + \mu \frac{\partial P_k}{\partial V_k} = V_k + \mu \left(I_k + V_k \cdot \frac{\partial I_k}{\partial V_k} \right), \quad (3.10)$$

gdje je k diskretni vremenski trenutak, dok je μ pozitivno pojačanje kojim se kontroliše brzina konvergencije rješenju. Algoritam će konvergirati brže za veću vrijednost μ , ali će, takođe, biti osjetljiviji na mjerne šumove. Ne postoji analitički pristup za određivanje maksimalne vrijednosti parametra μ , ali se on vrlo jednostavno može posetiti eksperimentalnim putem. Pri tome, treba voditi računa o pravilu da funkcija koja se brže mijenja zahtijeva manju vrijednost pojačanja.

Jednačina fotonaponskog panela (1.11) ima implicitan oblik, zbog čega se ne može direktno koristiti za računanje parcijalnog izvoda u izrazu (3.10). S druge strane, NN model omogućava direktnu eksplicitnu zavisnost između struje i napona. Prema tome, diferencijacijom jednačine (3.5) u zavisnosti od napona, traženi parcijalni izvod dobija oblik:

$$\frac{\partial \hat{P}_k}{\partial V_k} = \hat{I}_k + V_k (\mathbf{W}_{1,3}^T \odot \mathbf{W}_2) \tanh'(\mathbf{W}_1 \mathbf{u}_k + \mathbf{b}_1), \quad (3.11)$$

gdje $\mathbf{W}_{1,3}$ predstavlja treću kolonu matrice \mathbf{W}_1 (kolona koja odgovara ulazu V), simbol \odot definiše skalarni proizvod između vektora i matrice, dok je $\tanh'(x) = 1 - \tanh(x)^2$ izvod od $\tanh(x)$.

Važno je naglasiti da, ukoliko se vrši pretprocesiranje podataka pri treniranju NN modela, treba uzeti u obzir funkciju pretprocesiranja prilikom računanja (3.11). Na

primjer, ako je izvršeno preprocesiranje trening seta upotrebom (3.6), tada drugi član u jednačini (3.11) treba pomnožiti sa $[u_{V,\max} - u_{V,\min}]^{-1}$, gdje je $u_{V,\max}/u_{V,\min}$ maksimalna/minimalna vrijednost napona V u datasetu.

Može se očekivati da će NMPPT algoritam konvergirati brže od model-free MPPT algoritama, gdje se gradijent proračunava heuristički, upotrebom mjerenja struje i napona. Takođe, NMPPT algoritam zahtijeva poznavanje samo jedne vrijednosti temperature i iradijanse za određivanje MPP. Iz tog razloga, gradijentno pravilo (3.10) se može primijeniti više puta u toku jednog vremenskog trenutka, zbog čega se dodatno povećava brzina konvergencije. Međutim, ovaj proces uvećava i računsku kompleksnost algoritma, zbog čega je potrebno pronaći kompromis između brzine konvergencije i složenosti. Takođe, potrebno je naglasiti da se ova tehnika ne može primijeniti kod model-free algoritama, zato što oni zahtijevaju novo mjerenje struje za proračun svakog narednog koraka.

3.4.2 Estimacija solarne iradijanse

Osim opisane NMPPT tehnike, veoma je važno dotaći se problema senzora iradijanse, s obzirom na to da je informacija o iradijansi potrebna za implementaciju ove tehnike. U praksi, senzori iradijanse su prilično skupi i teški za kalibraciju. Iz tog razloga, razvijeni su mnogi algoritmi za estimaciju iradijanse, koji se međusobno razlikuju po tačnosti, računskoj kompleksnosti i neophodnim PV parametrima.

U ovom radu je predstavljen estimator iradijanse koji je baziran na prethodno definisanom NN modelu panela. Glavna prednost ovog estimatora je vrlo jednostavna struktura, pri čemu je za njegovu implementaciju potrebno samo nekoliko dodatnih računskih operacija u odnosu na broj operacija potrebnih za izvršavanje NMPPT algoritma sa poznatom iradijansom. Predloženi estimator iradijanse, razvijen prema literaturi [60], se oslanja na princip imerzije i invarianse (NI&I estimator). Uz pretpostavku da je moguće izmjeriti vrijednosti I i T , greška između mjerene i predviđene vrijednosti struje dobija sljedeći oblik:

$$e_k = I - \hat{I} = I_k - \text{net}\left(T_k, \hat{G}_k, V_k\right). \quad (3.12)$$

Tada, NI&I estimator:

$$\hat{G}_{k+1} = \hat{G}_k + \gamma e_k, \quad (3.13)$$

za $\gamma > 0$, zadovoljava:

$$\lim_{k \rightarrow \infty} \hat{G}_k \rightarrow G,$$

za sve početne uslove G_0 i sve pozitivne signale I_k, V_k, T_k . Neophodan uslov za postizanje konvergencije je da je funkcija e_k monotono rastuća, što je analitički dokazano u [60]. S druge strane, poznato je da se struja panela povećava sa povećanjem iradijanse.

Brži estimator – neuralni gradijentni estimator (NGE), se može definisati ukoliko se cost funkcija izrazi pomoću kvadratne greške e_k , a zatim minimizuje upotrebom metoda opadajućeg gradijenta:

$$\hat{G}_{k+1} = \hat{G}_k - \delta \frac{\partial e_k^2}{\partial \hat{G}_k} \quad (3.14)$$

Kako e_k monotono opada, e_k^2 će biti konveksna i imaće samo jedan minimum.

Diferencijacijom izraza (3.5) u zavisnosti od iradijanse, a zatim uvrštavanjem u (3.14), gradijentno pravilo dobija oblik:

$$\hat{G}_{k+1} = \hat{G}_k + 2\delta (\mathbf{W}_{1,2}^T \odot \mathbf{W}_2) \tanh'(\mathbf{W}_1 \mathbf{u}_k + \mathbf{b}_1) e_k, \quad (3.15)$$

gdje je $\mathbf{W}_{1,2}$ druga kolona matrice \mathbf{W}_1 (kolona koja odgovara ulazu G), dok je δ pojačanje pozitivne vrijednosti.

Pseudokod predloženog NMPPT algoritma u kombinaciji sa NI&I estimatorom je dat u nastavku:

Pseudokod 1 NMPPT algoritam i NI&I estimator

Inicijalizacija: $V(0)$, $\hat{G}(0)$

for svaki vremenski trenutak k

1: izmjeriti I_k, V_k, T_k

2: **for** $i = 1, \dots, P$ **do**

3: $\mathbf{u} = [T_{k,i} \ \hat{G}_{k,i} \ V_{k,i}]^T$

4: $\hat{I}_{k,i} = net(T_{k,i}, \hat{G}_{k,i}, V_{k,i})$

5: $\frac{\partial \hat{P}_{k,i}}{\partial V_k} = \hat{I}_{k,i} + V_{k,i} (\mathbf{W}_{1,3}^T \odot \mathbf{W}_2) \tanh'(\mathbf{W}_1 \mathbf{u} + \mathbf{b}_1)$

6: $V_{k,i+1} = V_{k,i} + \mu \frac{\partial \hat{P}_{k,i}}{\partial V_k}$

7: $e_{k,i} = I_k - \hat{I}_{k,i}$

8: $\hat{G}_{k,i+1} = \hat{G}_{k,i} + \gamma e_{k,i}$

9: **end for**

10: $\hat{G}_{k+1,1} = \hat{G}_{k,P}$

end for

3.4.3 Računska kompleksnost predloženog rješenja

Pseudokod (1) predloženog NMPPT algoritma i NI&I estimatora daje dobar uvid u broj računskih operacija potrebnih za njihovu implementaciju. Ukoliko pretpostavimo da skriveni sloj NN modela ima M neurona, tada će NMPPT algoritam uključivati $5M + 2$ operacija množenja i $5M + 2$ operacija sabiranja. Štaviše, samo jedna operacija množenja i dvije operacije sabiranja su potrebne za implementaciju NI&I estimatora, dok NGE zahtijeva M operacija sabiranja i M operacija množenja. Takođe, važno je istaći i činjenicu da će se računska kompleksnost približno povećati P puta, ukoliko se svi koraci algoritma izvrše P puta. Na primjer, ako je $M = 4$ i $P = 2$, tada će predloženi NMPPT algoritam zahtijevati 42 operacije sabiranja i 44 operacije množenja. Za isti slučaj, EMPPT model-based algoritam opisan u prethodnom poglavlju, koji će u narednom poglavlju biti poređen sa ostalim MPPT algoritmima, zahtijeva 32 operacije sabiranja i 66 operacija množenja [59].

Glava 4

Rezultati simulacija

U ovom poglavlju su prikazani rezultati simulacija kojima su potvrđene prednosti predloženih algoritama. Najprije je izvršena komparativna analiza između jednostavnog NN modela panela (sekcija 3.2) i NN modela kompleksnije arhitekture, čime je dokazano da se solarni panel može modelovati pomoću vrlo jednostavne neuralne mreže. Drugi dio ovog poglavlja se odnosi na komparaciju predloženog NMPPT algoritma (sekcija 3.4) sa drugim MPPT algoritmima, i to u kombinaciji sa estimatorima iradijanse opisanim u sekciji 3.4.2. Sve simulacije su izvršene u softverskom paketu Matlab R2017a/Simulink.

4.1 Komparativna analiza predloženog modela neuralne mreže sa modelom mreže drugačije arhitekture

U cilju testiranja performansi različitih arhitektura NN modela panela, najprije je formiran Simulink model ekvivalentnog električnog kola solarnog panela kako bi se omogućilo prikupljanje podataka za treniranje neuralne mreže. Navedeni model se sastoji od ukupno 90 solarnih čelija (5 serijski povezanih modula, koji se sastoje od po 18 serijski vezanih čelija). Karakteristike solarne čelije, koje su odredene pri iradijansi 1000 W/m^2 , date su u tabeli 4.1.

Struja kratkog spoja, $I_{sc}[\text{A}]$	7.34
Napon praznog hoda, $V_{oc}[\text{V}]$	0.6
Faktor kvaliteta diode, n	1.5
Serijska otpornost, $R_s[\Omega]$	0.001

Tabela 4.1: Karakteristike solarne čelije

Vrijednosti ulaznih parametara neuralne mreže se zadaju u sljedećim intervalima: solarna iradijansa $G \in \{50, 1000\}$, temperatura $T \in \{0, 75\}$ i izlazni napon panela $V \in \{0, 54\}$, pri čemu se temperatura T konkretno odnosi na temperaturu solarne čelije, odnosno solarnog panela. Izlazni parametar mreže je izlazna struja panela I . Analizirana su dva slučaja, pri čemu je u prvom slučaju usvojena mreža sa jednim skrivenim slojem i tri neurona u njemu, a u drugom slučaju mreža sa dva skrivena sloja koja se sastoje od četiri i tri neurona, respektivno.

Takođe, definisani su uslovi treniranja opisanih neuralnih mreža. Željena srednja kvadratna greška MSE ima vrijednost 1×10^{-10} . Za treniranje mreža se koristi 50 uzoraka sa I - V krive, pri čemu su 50 parova (G, T) na slučajan način odabrani iz definisanog skupa vrijednosti.

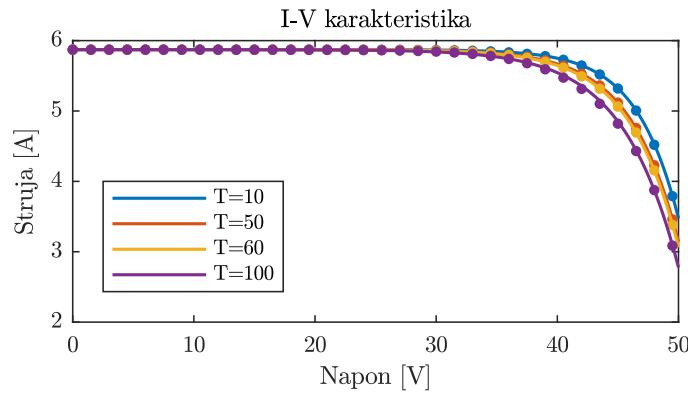
Na kraju je izvršeno poređenje I - V karakteristika generisanih pomoću NN modela i ekvivalentnog kola panela istih karakteristika kao kod kola korištenog pri treniranju. Razmatrana su dva različita slučaja. U prvom slučaju je definisana konstantna vrijednost solarne iradijanse $G = 800\text{W/m}^2$, dok su vrijednosti temperature $T \in \{10^\circ\text{C}, 50^\circ\text{C}, 60^\circ\text{C}, 100^\circ\text{C}\}$. U drugom slučaju se definiše konstantna vrijednost temperature $T = 25^\circ\text{C}$, dok solarna iradijansa ima sljedeće vrijednosti $G \in \{200\text{W/m}^2, 600\text{W/m}^2, 1000\text{W/m}^2, 1400\text{W/m}^2\}$. Uz to, u oba slučaja se izlazni napon panela mijenja u opsegu $V \in \{0, 54\}$. Osim toga, za testiranje mreže je uzeta 50001 tačka sa I - V , odnosno P - V krive. Takođe, važno je napomenuti da vrijednosti temperature i iradijanse za koje je izvršeno testiranje ne pripadaju trening setu NN modela.

U nastavku su prikazani rezultati analize dva prethodno navedena NN modela, koji se sastoje od različitog broja skrivenih slojeva i neurona.

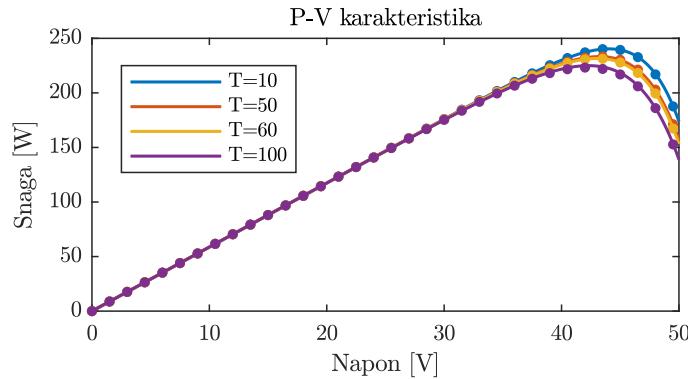
4.1.1 NN model: jedan skriveni sloj, tri neurona

Dakle, u ovom primjeru je usvojena neuralna mreža koja ima jedan skriveni sloj i tri skrivena neurona (NN_3). Za treniranje mreže je potrebno 949 epoha, pri čemu je postignuta srednja kvadratna greška 4.5×10^{-6} . Na slici 4.1 su date I - V i P - V karakteristike simuliranog panela, označene punom linijom, i NN modela, koje su označene pomoću tačaka. Pri tome, na slici 4.1a i 4.1b su prikazane I - V i P - V karakteristike panela za konstantnu iradijansu i različite vrijednosti temperature, a na slici 4.1c i 4.1d I - V i P - V karakteristike panela za konstantnu temperaturu i različite vrijednosti iradijanse.

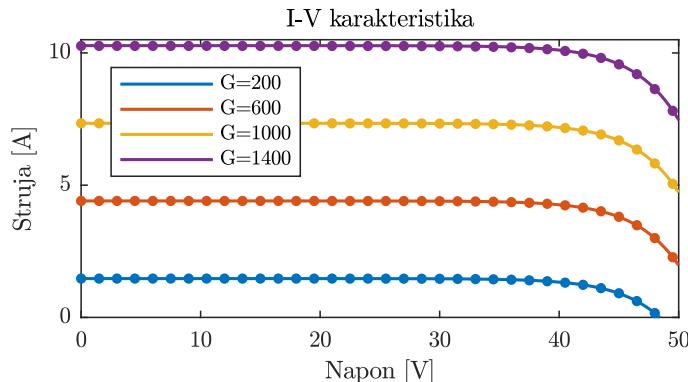
Može se primijetiti da se, za vrijednosti podataka za koje je mreža istrenirana, karakteristike modela mreže dosta dobro poklapaju sa karakteristikama simuliranog modela. Međutim, u slučaju kada je temperatura 100°C , kao i u slučaju kada je iradijansa 1400W/m^2 , javlja se vrlo malo odstupanje od stvarnih vrijednosti, što je i očekivano s obzirom na to da ove vrijednosti izlaze iz opsega za koje je trenirana mreža. Važno je naglasiti da NN model dobro aproksimira karakteristiku panela na čitavom opsegu napona, te da je zbog bolje preglednosti x -osa ograničena na 50V.



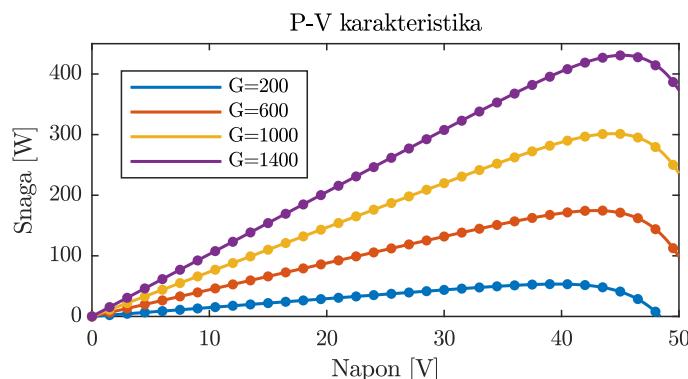
(a) I - V karakteristika pri promjeni temperature



(b) P - V karakteristika pri promjeni temperature



(c) I - V karakteristika pri promjeni solarne iradijanse



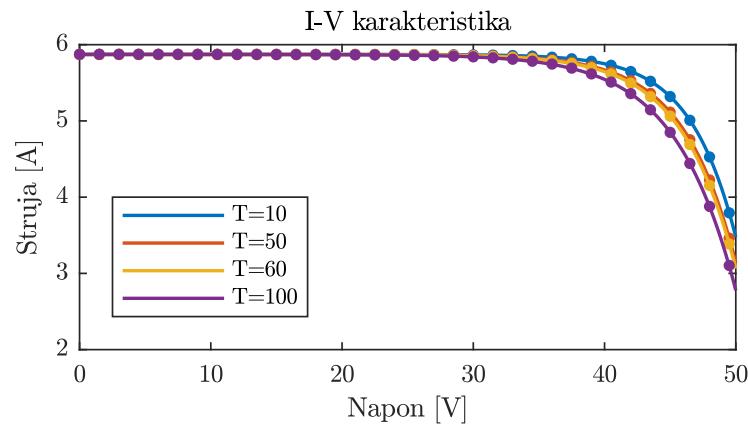
(d) P - V karakteristika pri promjeni solarne iradijanse

Slika 4.1: Komparacija karakteristika simuliranog ekvivalentnog kola panela i NN_3 modela neuralne mreže

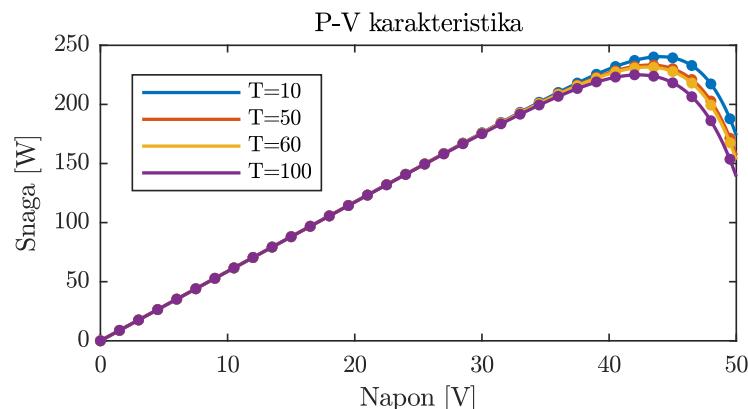
4.1.2 NN model: dva skrivena sloja, četiri-tri neurona

U ovom primjeru je usvojen malo kompleksniji model neuralne mreže, koji se sastoji od dva skrivena sloja, sa četiri i tri neurona, respektivno (NN_{43}). Za treniranje mreže opisane strukture je potrebno 5266 epoha, pri čemu je ostvarena srednja kvadratna greška 6.2×10^{-8} . Na slici 4.2 su date I - V i P - V karakteristike simuliranog modela panela, označene punom linijom, i NN modela, koje su označene pomoću tačaka. Pri tome, na slici 4.2a i 4.2b su prikazane I - V i P - V karakteristike panela za konstantnu iradijansu i različite vrijednosti temperature, a na slici 4.2c i 4.2d I - V i P - V karakteristike panela za konstantnu temperaturu i različite vrijednosti iradijanse.

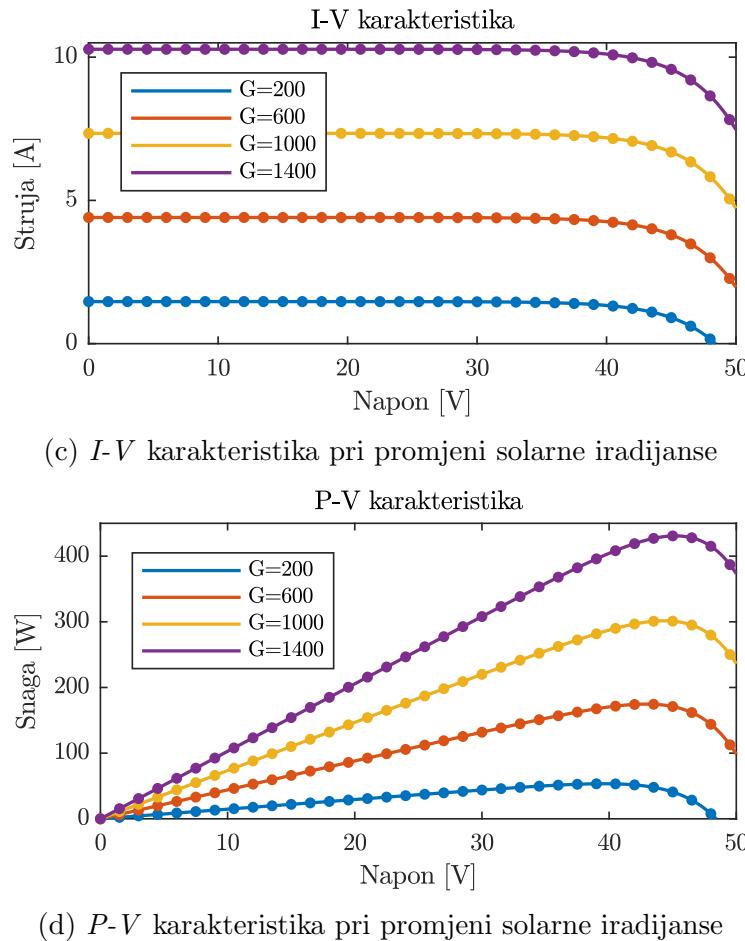
Može se zaključiti da opisana neuralna mreža daje bolje rezultate od mreže NN_3 , ne samo za vrijednosti za koje je trenirana, već i za one koje značajno odstupaju od njih (slučaj kada je temperatura 100°C , kao i kada je iradijansa 1400W/m^2).



(a) I - V karakteristika pri promjeni temperature



(b) P - V karakterистика при промјени температуре



Slika 4.2: Komparacija karakteristika simuliranog ekvivalentnog kola panela i NN_{43} modela neuralne mreže

4.1.3 Poređenje performansi NN_3 i NN_{43} modela

Na kraju, izvršeno je poređenje performansi usvojenih modela neuralnih mreža. U tabeli 4.2 su date vrijednosti grešaka koje se javljaju pri konstantnoj iradijansi i promjeni temperature, dok su u tabeli 4.3 prikazane vrijednosti grešaka pri konstantnoj temperaturi i promjeni solarne iradijanse. Konkretno, kao indikatori performansi predstavljene su sljedeće greške:

- MSE – srednja kvadratna greška ostvarena prilikom treniranja neuralne mreže (za čitav skup podataka koji se koristio za treniranje);
- MSEI – srednja kvadratna razlika između struje simuliranog panela i struje predviđene NN modelom (za validaciju je uzeta 50001 tačka sa *I-V* krive)
- MSEP – srednja kvadratna razlika između snage simuliranog panela i snage predviđene NN modelom (za validaciju je uzeta 50001 tačka sa *P-V* krive)
- EP – razlika između maksimalne snage simuliranog panela i maksimalne snage predviđene NN modelom

Tabela 4.2: Pregled vrijednosti grešaka NN modela, pri promjeni temperature

NN₃				
<i>G</i> [W/m ²]	800			
<i>T</i> [°C]	10	50	60	100
MSE	4.4993×10^{-6}			
MSEI	4.77×10^{-6}	3.77×10^{-6}	3.08×10^{-6}	1.85×10^{-4}
MSEP	0.0098	0.0069	0.0049	0.3335
EP	5.92×10^{-4}	0.0895	0.1209	1.7650

NN₄₃				
<i>G</i> [W/m ²]	800			
<i>T</i> [°C]	10	50	60	100
MSE	6.1961×10^{-8}			
MSEI	4.70×10^{-8}	3.42×10^{-8}	2.48×10^{-8}	5.62×10^{-6}
MSEP	8.92×10^{-5}	4.23×10^{-5}	4.10×10^{-5}	0.0094
EP	1.06×10^{-4}	0.0027	0.0033	0.1042

Tabela 4.3: Pregled vrijednosti grešaka NN modela, pri promjeni solarne iradijanse

NN₃				
<i>T</i> [°C]	25			
<i>G</i> [W/m ²]	200	600	1000	1400
MSE	4.4993×10^{-6}			
MSEI	3.59×10^{-6}	3.51×10^{-6}	3.64×10^{-6}	9.55×10^{-5}
MSEP	0.0074	0.0071	0.0062	0.0773
EP	0.0219	0.1637	0.1992	0.1967

NN₄₃				
<i>T</i> [°C]	25			
<i>G</i> [W/m ²]	200	600	1000	1400
MSE	6.1961×10^{-8}			
MSEI	1.16×10^{-7}	7.70×10^{-8}	5.69×10^{-8}	4.20×10^{-8}
MSEP	1.88×10^{-4}	1.16×10^{-4}	8.67×10^{-5}	7.77×10^{-5}
EP	0.0173	0.0039	0.0165	0.0236

Na osnovu podataka u tabeli 4.2 i tabeli 4.3, može se primijetiti da model NN_{43} daje bolje rezultate od NN_3 . Upravo to je i očekivano, s obzirom na to da se NN_{43} sastoji od više skrivenih slojeva, a samim tim i više skrivenih neurona. S druge strane, model NN_3 ima manju računsku kompleksnost, pri čemu i dalje ostvaruje zadovoljavajuću tačnost. Prema tome, zaključuje se da neuralne mreže manje kompleksnosti imaju mogućnost postizanja rezultata zadovoljavajuće tačnosti, zbog čega predstavljaju dobar izbor u modelovanju nelinearnog solarnog sistema.

4.2 Komparativna analiza predloženog NMPPT algoritma sa drugim MPPT algoritmima

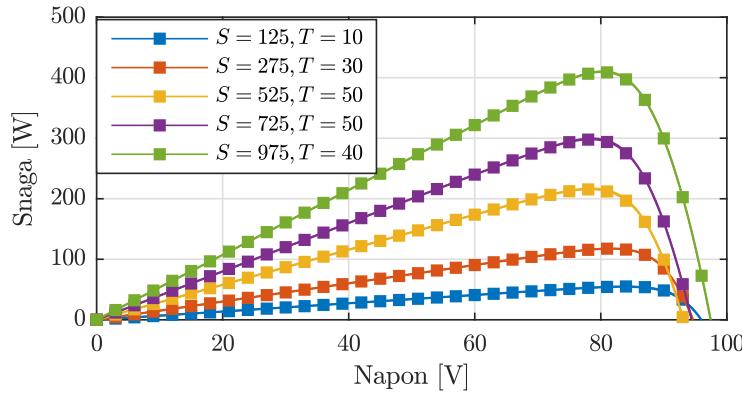
U ovoj sekciji je izvršeno poređenje performansi predloženog NMPPT algoritma sa drugim MPPT algoritmima, kao što su model-free P&O algoritam sa varijabilnim perturbacionim korakom [69] (sekcija 2.4.1), model-based CNNMPPT algoritam [94] (sekcija 3.3) i EMPPT algoritam [59] (sekcija 2.6). Pri tome, EMPPT [59] i CNNMPPT algoritmi koriste EEST i CNNEST estimatore iradijanse, respektivno.

U prvom dijelu je izvršena komparacija navedenih MPPT algoritama pomoću simuliranih podataka, pri čemu su $I-V$ krive generisane od strane ekvivalentnog kola panela. Razmatrano ekvivalentno kolo panela se sastoji od dva serijski povezana modula, sa 60 serijski vezanih čelija po modulu, čiji su parametri: $I_{ph} = 5.447 \text{ A}$, $I_s = 4.839 \times 10^{-12} \text{ A}$, $R_p = 309.047 \Omega$, $R_s = 0.566 \Omega$, $V_t = 1.807 \text{ V}$. S druge strane, u drugom dijelu se koriste eksperimentalni podaci, odnosno realne izmjerene $I-V$ krive koje čine dio velikog dataseta obezbijeđenog od strane National Renewable Energy Laboratory (NREL) [103]. Za potrebe ove analize, odabran je dataset panela koji je određen NREL kodom: HIT05662. Pri tome, HIT05662 panel je modelovan ekvivalentnim kolom čiji su parametri isti kao kod kola iz prvog dijela.

Važno je napomenuti da je usvojena ona arhitektura NN modela koja je pokazivala najbolje rezultate u razmatranim slučajevima. Prema tome, u svim primjerima se primjenjuje NN model koji se sastoji od 4 skrivena neurona. CNNMPPT algoritam je, takođe, kreiran od 4 neurona radi izvršenja fer komparacije, dok su parametri P&O i EMPPT algoritma odabrani tako da obezbjeđuju najbolje performanse. Parametri predloženog metoda su $\mu = 0.8$, $\gamma = 50$, $\delta = 1500$ u prvom dijelu, odnosno $\mu = 1.5$, $\gamma = 50$ u drugom dijelu analize.

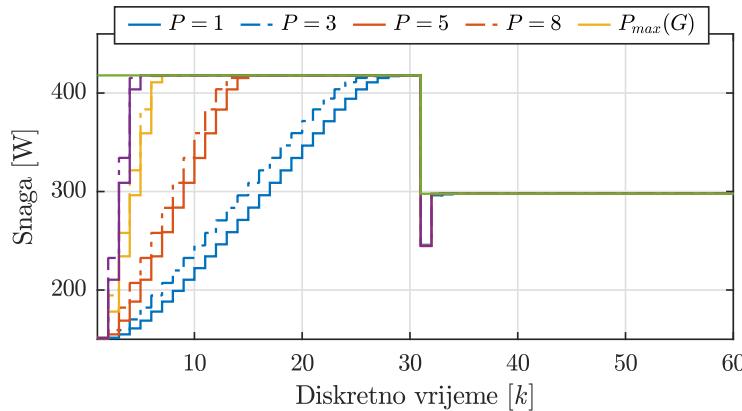
4.2.1 Primjena simuliranih podataka

Dakle, u ovom dijelu se treniranje neuralne mreže vrši pomoću podataka generisanih od strane ekvivalentnog kola panela, pri čemu se u tu svrhu koristi 200 uzoraka sa $I-V$ krive, odnosno 200 parova (G, T) ravnomjerno raspoređenih u okviru opsega $G \in \{50, 1100\}$ i $T \in \{5, 50\}$. Svaka $I-V$ kriva se sastoji od 100 radnih tačaka. Na slici 4.3 su prikazane $P-V$ karakteristike simuliranog panela (puna linija) i NN modela (puna linija sa kvadratima) za vrijednosti iradijanse i temperature koje ne pripadaju trening setu. Može se primjetiti da se $P-V$ karakteristike NN modela veoma dobro poklapaju sa $P-V$ karakteristikama simuliranog panela. Srednja kvadratna greška MSE ostvarena na trening setu iznosi 2.92×10^{-5} , dok je MSE za validacioni set 3.81×10^{-5} .

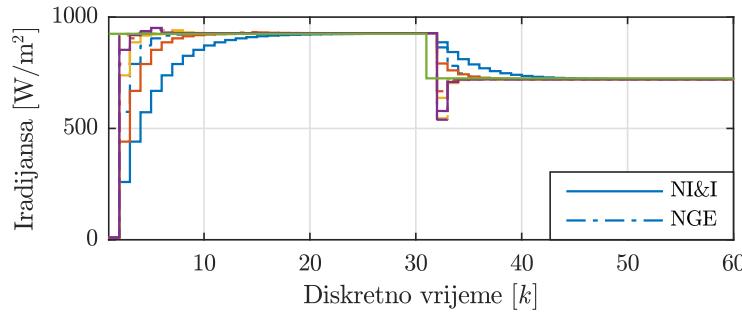


Slika 4.3: Komparacija P - V karakteristika panela generisanih od strane ekvivalentnog kola i NN modela panela

U prvom primjeru su analizirane performanse predloženog NMPPT algoritma za različite vrijednosti iradijanse, sa ciljem definisanja optimalnog broja puta izvršenja svih koraka algoritma P , kao i estimatora iradijanse koji će se koristiti u daljim analizama. Konkretno, u toku prvih 30 iteracija, vrijednosti iradijanse i temperature iznose $G = 925 \text{ W/m}^2$ i $T = 10^\circ\text{C}$, nakon čega se mijenjaju na $G = 725 \text{ W/m}^2$ i $T = 50^\circ\text{C}$. Estimacija iradijanse je najprije izvršena pomoću NI&I estimatorsa. Na slici 4.4b se može primijetiti da NI&I estimator konvergira u 15 iteracija, za $P = 1$. S druge strane, brzina konvergencije i NI&I estimatorsa i NMMPT algoritma se povećava za veće vrijednosti P (slika 4.4a). Osim toga, posmatran je i slučaj kombinacije NGE estimatorsa iradijanse sa NMPPT algoritmom. Na osnovu slike 4.4b se može zaključiti da NGE ima veću brzinu konvergencije od NI&I, što takođe uslovjava povećanje brzine konvergencije NMPPT algoritma. Uzimajući u obzir balans između brzine konvergencije i računske kompleksnosti, u narednim analizama su korišteni NMPPT algoritam i NI&I za $P = 2$.



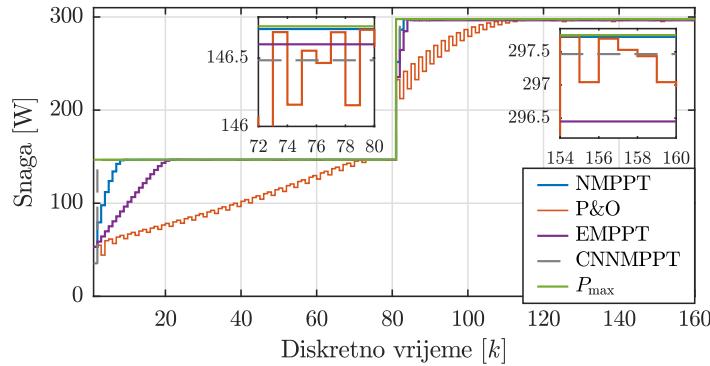
(a) NMPPT algoritam



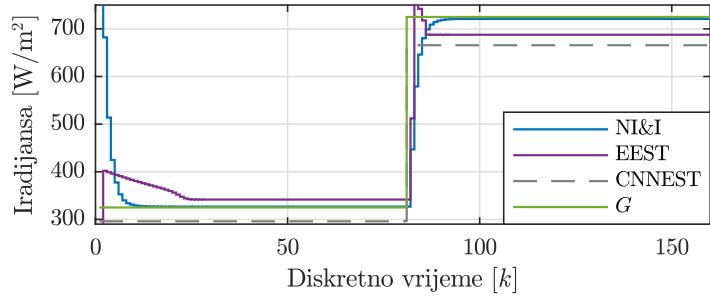
(b) Estimatori iradijanse

 Slika 4.4: Performansa predloženog algoritma za različite vrijednosti P

Drugi primjer se odnosi na poređenje performansi NMPPT, P&O, EMPPT and CNNMPPT algoritama pri nagloj promjeni solarne iradijanse i temperature. Naime, iradijansa i temperatura do osamdesete iteracije imaju vrijednosti $G = 320 \text{ W/m}^2$ i $T = 10^\circ\text{C}$, kada se povećavaju na $G = 725 \text{ W/m}^2$ i $T = 50^\circ\text{C}$. Posmatrajući sliku 4.5a, može se zaključiti da CNNMPPT algoritam obezbjeđuje postizanje optimalnog napona gotovo trenutno, dok je NMPPT, EMPPT i P&O algoritmima potrebno 8, 20 i 75 iteracija da dostignu stacionarno stanje, respektivno. Osim toga, kod P&O algoritma se javljaju velike oscilacije u stacionarnom stanju, oko tačke maksimalne snage. S druge strane, NMPPT pokazuje najmanju grešku u stacionarnom stanju, bez pojave oscilacija. To se dešava iz razloga što NI&I obezbjeđuje veću tačnost od EEST and CNNEST estimatora iradijanse, što se može primijetiti na slici 4.5b.



(a) Prikaz MPPT algoritama

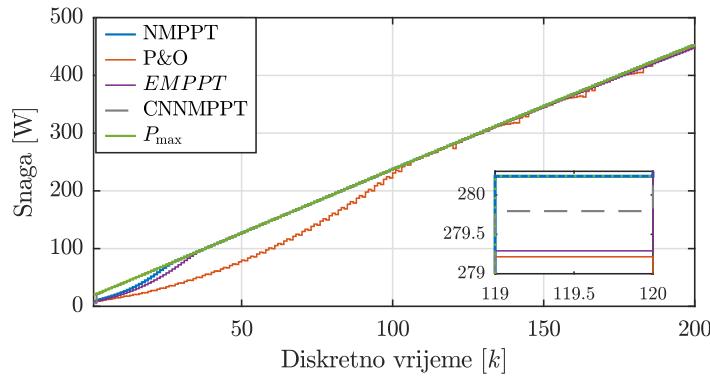


(b) Prikaz estimatorskih rezultata

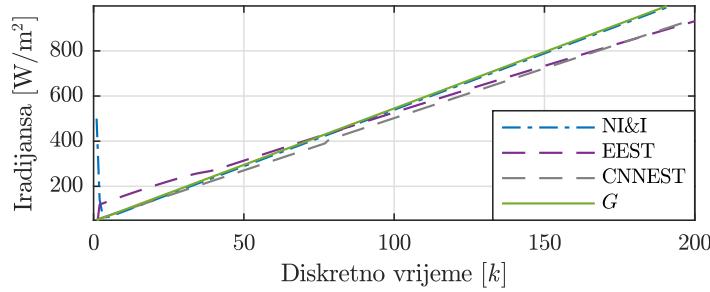
Slika 4.5: Komparacija algoritama pri nagloj promjeni solarne iradijanse i temperature

U posljednjem primjeru, iradijansa i temperatura se linearno mijenjaju u intervalima $G \in \{50, 1050\}$, i $T \in \{5, 55\}$. Posmatrajući sliku 4.6a, može se zaključiti da NMPPT, EMPPT i CNNMPPT omogućavaju dobro praćenje tačke maksimalne snage. S druge strane, P&O algoritam ima najmanju brzinu konvergencije, dok EMPPT pokazuje najveću grešku u stacionarnom stanju. Takođe, može se primijetiti da NI&I estimator iradijanse daje bolje rezultate u poređenju sa EEST i CNNEST (4.6b).

Relativne greške između predviđenih i stvarnih maksimalnih vrijednosti snage, za različite vrijednosti iradijanse, su date u tabeli 4.4. Može se primjetiti da predloženi NMPPT algoritam, nakon ulaska u stacionarno stanje, dostiže tačku maksimalne snage sa greškom manjom od 0.001%. S druge strane, P&O, EMPPT i CNNMPPT pokazuju relativne greške koje dostižu čak i vrijednosti 1.138%, 2.118% i 0.171%, respektivno.



(a) Prikaz MPPT algoritama



(b) Prikaz estimatora iradijanse

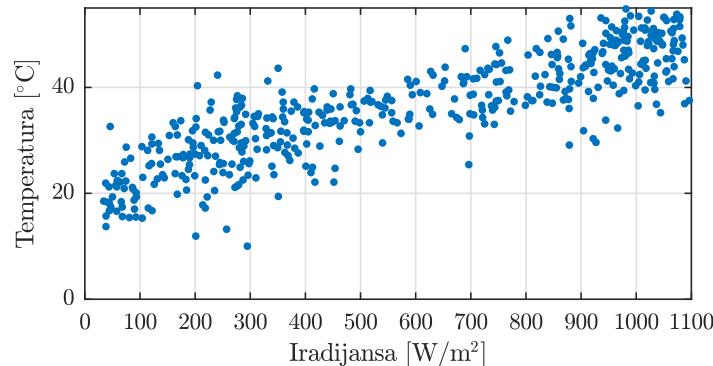
Slika 4.6: Komparacija algoritama pri linearnoj promjeni solarne iradijanse i temperature

Tabela 4.4: Prikaz relativnih grešaka između predviđene i stvarne vrijednosti maksimalne snage

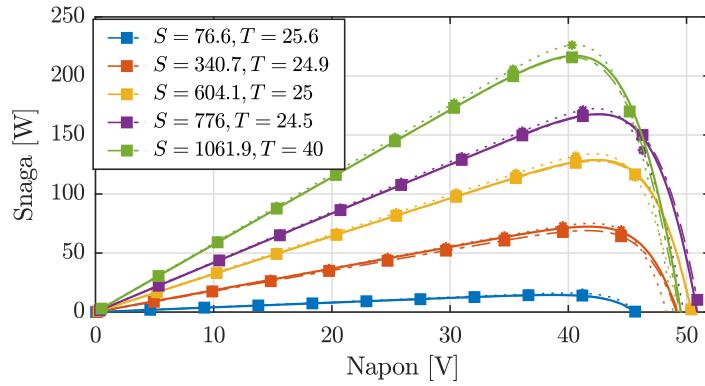
k	G	P_{max}	Relativna greška predikcije (%)			
			NMPPT	P&O	EMPPT	CNNMPPT
20	140	59.429	18.881	32.397	56.772	0.251
40	240	103.593	0.004	0.011	46.72	0.003
60	340	147.954	0.002	0.089	31.677	0.084
80	440	192.26	0.001	0.148	18.353	0.148
100	540	236.382	0.0001	0.224	6.007	0.171
120	640	280.24	0.001	0.339	0.366	0.159
140	740	323.775	0.0001	0.485	2.118	0.124
160	840	366.95	0.001	0.668	1.509	0.079
180	940	409.733	0.0001	0.885	1.708	0.036
200	1040	452.106	0.001	1.138	1.004	0.008

4.2.2 Primjena eksperimentalnih podataka

Za razliku od prethodnog slučaja, u ovom dijelu se neuralna mreža trenira pomoću 500 uzoraka sa I - V krive, odnosno 500 parova (G, T) ravnomjerno raspoređenih u okviru opsega $G \in \{50, 1100\}$ i $T \in \{5, 50\}$ (slika 4.7). Svaka I - V kriva se sastoji od 180 radnih tačaka. Na slici 4.8 su prikazane P - V karakteristike panela za vrijednosti iradijanse i temperature koje ne pripadaju trening setu. Konkretno, date su mjerene P - V karakteristike panela (puna linija), kao i P - V karakteristike NN modela treniranog pomoću simuliranih podataka NN_s (tačkasta linija sa zvijezdama) i NN modela treniranog pomoću eksperimentalnih podataka NN_e (isprekidana linija sa kvadratima). Može se primjetiti da se P - V karakteristike NN_e modela poklapaju veoma dobro sa mjerjenim karakteristikama: MSE za trening set iznosi 0.0027, dok je MSE ostvarena na validacionom setu 0.0028. S druge strane, MSE NN_s modela ima vrijednost 0.0612 na validacionom setu. Takođe, važno je napomenuti da će NMPPT/NI&I zasnovani na simuliranim podacima u nastavku biti označeni kao NMPPT_s/NI&I_s, a u slučaju kada su zasnovani na eksperimentalnim podacima kao NMPPT_e/NI&I_e.

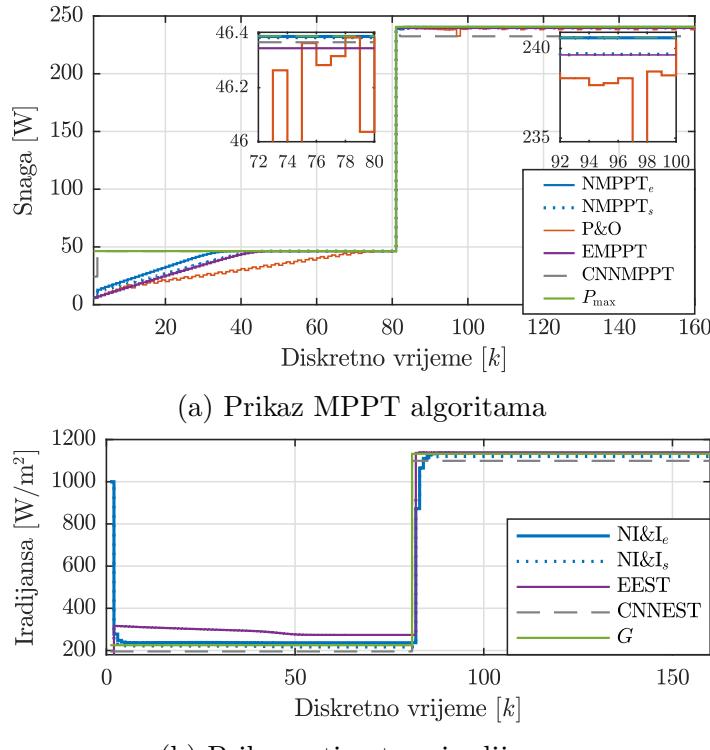


Slika 4.7: Eksperimentalni podaci korišteni za treniranje NN_e modela, odnosno NMPPT_e algoritma i NI&I_e estimatora iradijanse



Slika 4.8: Komparacija mjerenih P - V karakteristika i P - V karakteristika NN_s/NN_e modela

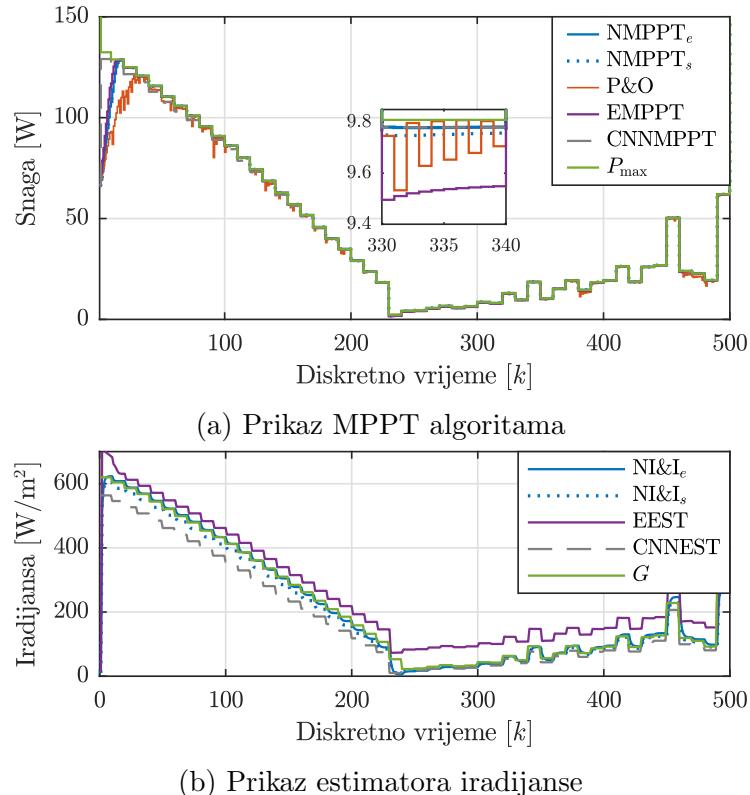
U prvom primjeru, izvršena je komparacija MPPT algoritama pri nagloj promjeni iradijanse. Pri tome, iradijansa do osamdesete iteracije ima vrijednost $G = 225 \text{ W/m}^2$, kada se povećava na $G = 1132 \text{ W/m}^2$. Posmatrajući sliku 4.9a, može se zaključiti da CNNMPPT algoritam i sada obezbjeđuje postizanje optimalnog napona gotovo trenutno, dok je NMPPT_e, NMPPT_s, EMPPT i P&O algoritmima potrebno 40, 47, 48 i 75 iteracija da dostignu stacionarno stanje, respektivno. S druge strane, NMPPT_e pokazuje najmanju grešku u stacionarnom stanju, kojeg redom prate NMPPT_s, EMPPT, P&O i CNNNPPT. To se dešava iz razloga što NI&I obezbjeđuje veću tačnost od EEST i CNNEST estimatora iradijanse, što se može primijetiti na slici 4.9b.



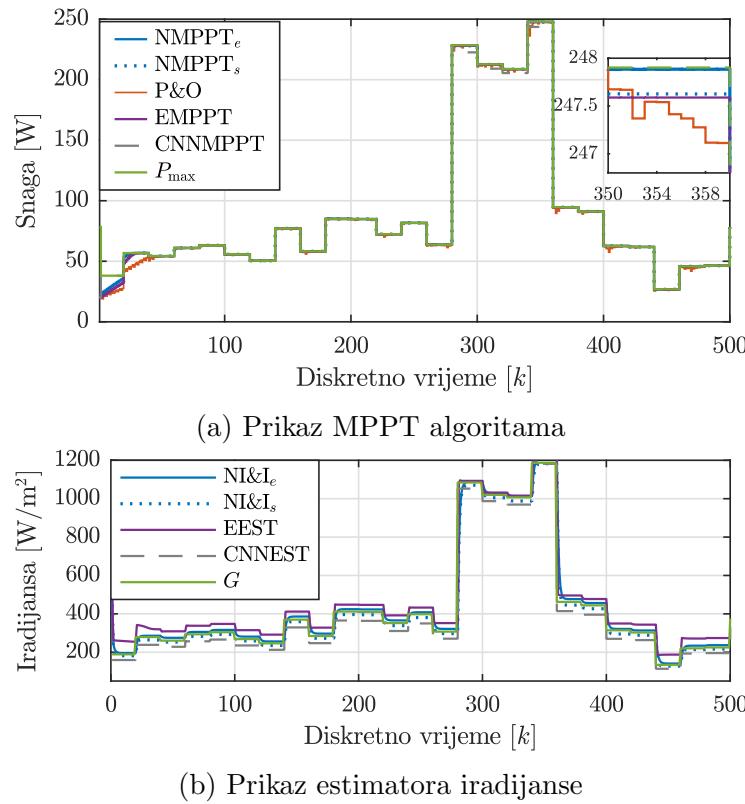
Slika 4.9: Komparacija algoritama pri nagloj promjeni solarne iradijanse i temperature

Konačno, u posljednjem primjeru su razmatrana dva slučaja promjene iradijanse i temperature, čije se vrijednosti zadaju nasumično. Odgovarajući rezultati simulacija su prikazani na slikama 4.10 i 4.11, a na osnovu njih se mogu izvesti slični zaključci kao u prethodnom primjeru. Dakle, $NMPPT_e$ algoritam i $NI\&I_e$ estimator bazirani na eksperimentalnim podacima obezbjeđuju najbolje performanse. S druge strane, $NMPPT_s$ i EMPPT takođe postižu zadovoljavajuće rezultate, P&O ima najmanju brzinu konvergencije i velike oscilacije u stacionarnom stanju, dok CNNMPPT za neke vrijednosti iradijanse pokazuje visoku tačnost, a za druge ima najgoru performansu. Kada je riječ o estimatorima performanse, nakon $NI\&I_e$ estimatorsa najbolje performanse postiže $NI\&I_s$, a manju tačnost pokazuju EEST i CNNEST.

Relativne greške između predviđenih i stvarnih maksimalnih vrijednosti snage, za različite vrijednosti iradijanse, su date u tabeli 4.4. Može se primijetiti da $NMPPT_e$ algoritam, nakon ulaska u stacionarno stanje, dostiže tačku maksimalne snage sa greškom manjom od 0.1%. S druge strane, $NMPPT_s$, EMPPT, P&O i CNNMPPT pokazuju relativne greške koje dostižu čak i vrijednosti 0.2259%, 0.408%, 1.856% i 2.586%, respektivno.



Slika 4.10: Komparacija algoritama pri različitim varijacijama solarne iradijanse u vremenu



Slika 4.11: Komparacija algoritama pri različitim varijacijama solarne iradijanse u vremenu

Tabela 4.5: Prikaz relativnih grešaka između predviđene i stvarne vrijednosti maksimalne snage

G	P_{max}	Relativna greška predikcije (%)				
		NMPPT _e	NMPPT _s	EMPPT	P&O	CNNMPPT
110.2	22.77	0.06	0.082	0.408	1.856	1.834
132.2	23.635	0.099	0.064	0.218	0.187	0.712
225.1	46.391	0.003	0.012	0.097	0.11	0.177
260.5	54.285	0.007	0.007	0.058	0.321	0.536
302.9	61.845	0.004	0.012	0.046	0.117	0.537
369.9	77.121	0.01	0.002	0.023	0.291	0.333
409.7	84.877	0.001	0.001	0.005	0.24	0.43
523.5	111.36	0.009	0.051	0.064	0.6328	0.016
613.3	120.578	0.006	0.267	0.023	0.027	0.04
653.8	133.64	0.007	0.01	0.016	1.746	0.046
713.40	153.97	0.0004	0.2259	0.2473	0.2680	0.9709
859.5	171.037	0.0001	0.005	0.002	0.006	0.262
946.8	198.125	0.001	0.142	0.163	0.72	0.572
1007.1	208.772	0.004	0.06	0.07	0.123	1.581
1084.3	228.473	0.003	0.173	0.118	0.209	2.586

Zaključak

U ovom radu je izvršeno modelovanje fotonaponskog panela na bazi neuralne mreže (NN model), kao jedne savremene soft-computing tehnike. Pri tome, primjena NN modela omogućava dobijanje eksplicitne zavisnosti između generisane struje panela, koja predstavlja izlazni parametar modela, i izlaznog napona panela, temperature solarne ćelije i solarne iradijanse, koji predstavljaju ulazne parametre modela. Na taj način, izbjegнута је upotreba iterativnih metoda za rješavanje implicitnih strujno-naponskih jednačina kojima se solarni panel najčešće predstavlja, te je tako pojednostavljena računska složenost modela.

Osim toga, razvijen je jednostavan gradijentni MPPT algoritam baziran na predloženom NN modelu. Pri tome, NN model se koristi za proračun gradijenta $P-V$ karakteristike u zavisnosti od napona, što omogućava brzo praćenje tačke maksimalne snage i visoku tačnost u stacionarnom stanju, bez pojave oscilacija. Dodatno, predložen je i estimator solarne iradijanse, koji se takođe oslanja na predloženi NN model. Važno je naglasiti da se ovaj NN model može obučiti upotrebom eksperimentalnih podataka, kao i pomoću podataka generisanih od strane ekvivalentnog kola panela.

U cilju testiranja performansi različitih NN modela panela (NN_3 i NN_{43}), izvršena je simulacija rada solarnog panela u softverskom paketu Matlab R2017a/Simulink. Na osnovu dobijenih rezultata se može zaključiti da neuralne mreže sa većim brojem skrivenih slojeva i neurona postižu rezultate visoke tačnosti. S druge strane, neuralne mreže jednostavnije arhitekture pokazuju malo manju, ali i dalje veoma zadovoljavajuću tačnost. Uzimajući u obzir balans između postignute tačnosti i računske kompleksnosti, zaključuje se da NN model manje kompleksnosti, a pri tome prilično zadovoljavajuće tačnosti, predstavlja odličan izbor u modelovanju ne-linearnog solarnog sistema.

Takođe, izvršene su i simulacije u cilju poređenja predloženog gradijentnog MPPT algoritma sa drugim efikasnim MPPT tehnikama koje su dostupne u literaturi. Konačni rezultati pokazuju da predloženi MPPT algoritam obezbjeđuje veću brzinu konvergencije nego ostali algoritmi. Osim toga, dokazano je da predloženi MPPT algoritam, odnosno njemu odgovarajući NN model, koji je zasnovan na eksperimentalnim podacima pokazuje najbolje performanse u stacionarnom stanju, dok MPPT algoritam/NN model zasnovan na simuliranim podacima, takođe, daje veoma zadovoljavajuće rezultate. Dodatno, predloženi estimator iradijanse baziran na NN modelu pokazuje bolju ili sličnu tačnost u odnosu na ostale razmatrane estimatore, što je veoma važno jer se estimatori iradijanse mogu koristiti i u druge svrhe, kao što su monitoring ili detekcija greške u solarnim sistemima. Konačno, predloženi pristup ne samo što pokazuje visok stepen tačnosti, već ima i nisku računsku kompleksnost

što ga čini podesnim za implementaciju na mikroprocesorskim platformama.

Predmet daljeg istraživanja će biti usmjeren na praktičnu realizaciju predloženih algoritama, kao i komparaciju njihovih performansi postignutih u realnim uslovima sa numeričkim rezultatima. Osim toga, budući rad će biti posvećen analizi pojave djelimične (neuniformne) zasjenčenosti solarnog panela, kada dolazi do pojave više lokalnih maksimuma na P - V karakteristici panela. U tom slučaju, predloženi MPPT algoritam bi trebalo da prepozna razliku između lokalnog i globalnog maksimuma. Takođe, biće analizirane performanse predloženog NN modela u drugim real-time primjenama, kao što su monitoring rada solarnog sistema, detekcija kvarova u solarnom sistemu, ili predikcija proizvodnje električne energije solarnog sistema.

Bibliografija

- [1] S. White, *Solar Photovoltaic Basics: A Study Guide for the NABCEP Entry Level Exam*. Taylor & Francis, 2014.
- [2] I. E. Agency, “Tracking clean energy progress 2017,” 2017.
- [3] V. Sivaram and S. Kann, “Solar power needs a more ambitious cost target,” *Nature Energy*, vol. 1, no. 4, pp. 1–3, 2016.
- [4] V. Sivaram, J. O. Dabiri, and D. M. Hart, “The need for continued innovation in solar, wind, and energy storage,” *Joule*, vol. 2, no. 9, pp. 1639–1642, 2018.
- [5] M. A. Green, Y. Hishikawa, E. D. Dunlop, D. H. Levi, J. Hohl-Ebinger, and A. W. Ho-Baillie, “Solar cell efficiency tables (version 52),” *Progress in Photovoltaics: Research and Applications*, vol. 26, no. 7, pp. 427–436, 2018.
- [6] “Cec inverter test protocol.”
- [7] L. Piegari and R. Rizzo, “Adaptive perturb and observe algorithm for photovoltaic maximum power point tracking,” *IET Renewable Power Generation*, vol. 4, no. 4, pp. 317–328, 2010.
- [8] S. Motahhir, A. El Hammouri, and A. El Ghzizal, “The most used mppt algorithms: Review and the suitable low-cost embedded board for each algorithm,” *Journal of cleaner production*, vol. 246, p. 118983, 2020.
- [9] L. M. Elbaid, A. K. Abdelsalam, and E. E. Zakzouk, “Artificial neural network-based photovoltaic maximum power point tracking techniques: a survey,” *IET Renewable Power Generation*, vol. 9, no. 8, pp. 1043–1063, 2015.
- [10] E. Moshksar and T. Ghanbari, “Adaptive estimation approach for parameter identification of photovoltaic modules,” *IEEE Journal of Photovoltaics*, vol. 7, no. 2, pp. 614–623, 2016.
- [11] V. Quaschning and R. Hanitsch, “Numerical simulation of current-voltage characteristics of photovoltaic systems with shaded solar cells,” *Solar energy*, vol. 56, no. 6, pp. 513–520, 1996.
- [12] A. Kapić, “Prijedlog algoritma za praćenje tačke maksimalne snage fotonaponskih panela,”
- [13] G. M. Masters, *Renewable and efficient electric power systems*. John Wiley & Sons, 2013.

- [14] J. H. Leck, *Theory of semiconductor junction devices: a textbook for electrical and electronic engineers*. Elsevier, 2013.
- [15] S. M. Sze and K. K. Ng, *Physics of semiconductor devices*. John wiley & sons, 2006.
- [16] A. Fahrenbruch and R. Bube, *Fundamentals of solar cells: photovoltaic solar energy conversion*. Elsevier, 2012.
- [17] A. McEvoy and T. Markvant, *Solar cells: materials, manufacture and operation*. Academic Press, 2012.
- [18] D. H. Muhsen, A. B. Ghazali, T. Khatib, and I. A. Abed, “Parameters extraction of double diode photovoltaic module’s model based on hybrid evolutionary algorithm,” *Energy Conversion and Management*, vol. 105, pp. 552–561, 2015.
- [19] M. Hejri, H. Mokhtari, M. R. Azizian, M. Ghandhari, and L. Söder, “On the parameter extraction of a five-parameter double-diode model of photovoltaic cells and modules,” *IEEE Journal of Photovoltaics*, vol. 4, no. 3, pp. 915–923, 2014.
- [20] M. Hadjab, S. Berrah, and A. Hamza, “Neural network for modeling solar panel,” *International journal of energy*, vol. 6, no. 1, pp. 9–16, 2012.
- [21] A. Galántai, “The theory of newton’s method,” *Journal of Computational and Applied Mathematics*, vol. 124, no. 1-2, pp. 25–44, 2000.
- [22] F. Mancilla-David, F. Riganti-Fulginei, A. Laudani, and A. Salvini, “A neural network-based low-cost solar irradiance sensor,” *IEEE Transactions on Instrumentation and Measurement*, vol. 63, no. 3, pp. 583–591, 2013.
- [23] M. G. Villalva, J. R. Gazoli, and E. Ruppert Filho, “Modeling and circuit-based simulation of photovoltaic arrays,” in *2009 Brazilian Power Electronics Conference*, pp. 1244–1254, IEEE, 2009.
- [24] D. S. Chan and J. C. Phang, “Analytical methods for the extraction of solar-cell single-and double-diode model parameters from iv characteristics,” *IEEE Transactions on Electron devices*, vol. 34, no. 2, pp. 286–293, 1987.
- [25] J.-P. Charles, I. Mekkaoui-Alaoui, G. Bordure, and P. Mialhe, “A critical study of the effectiveness of the single and double exponential models for i–v characterization of solar cells,” *Solid-State Electronics*, vol. 28, no. 8, pp. 807–820, 1985.
- [26] A. Polman, W. Van Sark, W. Sinke, and F. Saris, “A new method for the evaluation of solar cell parameters,” *Solar cells*, vol. 17, no. 2-3, pp. 241–251, 1986.
- [27] M. Hejri, H. Mokhtari, M. R. Azizian, and L. Söder, “An analytical-numerical approach for parameter determination of a five-parameter single-diode model of photovoltaic cells and modules,” *International Journal of Sustainable Energy*, vol. 35, no. 4, pp. 396–410, 2016.

- [28] J. Phang, D. Chan, and J. Phillips, "Accurate analytical method for the extraction of solar cell model parameters," *Electronics Letters*, vol. 20, no. 10, pp. 406–408, 1984.
- [29] N. Enebish, D. Agchbayar, S. Dorjkhand, D. Baatar, and I. Ylemj, "Numerical analysis of solar cell current-voltage characteristics," *Solar energy materials and solar cells*, vol. 29, no. 3, pp. 201–208, 1993.
- [30] A. Hovinen, "Fitting of the solar cell iv-curve to the two diode model," *Physica Scripta*, vol. 1994, no. T54, p. 175, 1994.
- [31] Z. Salam, K. Ishaque, and H. Taheri, "An improved two-diode photovoltaic (pv) model for pv system," in *2010 Joint International Conference on Power Electronics, Drives and Energy Systems & 2010 Power India*, pp. 1–5, IEEE, 2010.
- [32] G. Araujo, E. Sanchez, and M. Marti, "Determination of the two-exponential solar cell equation parameters from empirical data," *Solar cells*, vol. 5, no. 2, pp. 199–204, 1982.
- [33] J. Gow and C. Manning, "Development of a photovoltaic array model for use in power-electronics simulation studies," *IEE Proceedings-Electric Power Applications*, vol. 146, no. 2, pp. 193–200, 1999.
- [34] K. R. McIntosh, P. P. Altermatt, and G. Heiser, "Depletion-region recombination in silicon solar cells: when does $mdr = 2$," in *Proceedings of the 16th European photovoltaic solar energy conference*, pp. 251–254, 2000.
- [35] W. Durisch, O. Struss, and K. Robert, "Efficiency of selected photovoltaic modules under varying climatic conditions," in *World Renewable Energy Congress VI*, pp. 779–788, Elsevier, 2000.
- [36] W. Durisch, B. Bitnar, J.-C. Mayor, H. Kiess, K.-h. Lam, and J. Close, "Efficiency model for photovoltaic modules and demonstration of its application to energy yield estimation," *Solar energy materials and solar cells*, vol. 91, no. 1, pp. 79–84, 2007.
- [37] R. Ross Jr, "Interface design considerations for terrestrial solar cell modules," in *12th Photovoltaic Specialists Conference*, pp. 801–806, 1976.
- [38] A. Jain and A. Kapoor, "Exact analytical solutions of the parameters of real solar cells using lambert w-function," *Solar Energy Materials and Solar Cells*, vol. 81, no. 2, pp. 269–277, 2004.
- [39] E. I. Batzelis, I. A. Routsolias, and S. A. Papathanassiou, "An explicit pv string model based on the lambert w function and simplified mpp expressions for operation under partial shading," *IEEE Transactions on Sustainable Energy*, vol. 5, no. 1, pp. 301–312, 2013.
- [40] G. Liu, S. K. Nguang, and A. Partridge, "A general modeling method for i–v characteristics of geometrically and electrically configured photovoltaic arrays," *Energy conversion and management*, vol. 52, no. 12, pp. 3439–3445, 2011.

- [41] H. Kawamura, K. Naka, N. Yonekura, S. Yamanaka, H. Kawamura, H. Ohno, and K. Naito, "Simulation of i-v characteristics of a pv module with shaded pv cells," *Solar Energy Materials and Solar Cells*, vol. 75, no. 3-4, pp. 613–621, 2003.
- [42] S. Silvestre and A. Chouder, "Effects of shadowing on photovoltaic module performance," *Progress in Photovoltaics: Research and applications*, vol. 16, no. 2, pp. 141–149, 2008.
- [43] S. Silvestre, A. Boronat, and A. Chouder, "Study of bypass diodes configuration on pv modules," *applied energy*, vol. 86, no. 9, pp. 1632–1640, 2009.
- [44] M. Abramowitz and I. A. Stegun, *Handbook of mathematical functions with formulas, graphs, and mathematical tables*, vol. 55. US Government printing office, 1948.
- [45] M. Alonso-Garcia and J. Ruiz, "Analysis and modelling the reverse characteristic of photovoltaic cells," *Solar Energy Materials and Solar Cells*, vol. 90, no. 7-8, pp. 1105–1120, 2006.
- [46] J. Bishop, "Computer simulation of the effects of electrical mismatches in photovoltaic cell interconnection circuits," *Solar cells*, vol. 25, no. 1, pp. 73–89, 1988.
- [47] S. Miller, "Ionization rates for holes and electrons in silicon," *Physical Review*, vol. 105, no. 4, p. 1246, 1957.
- [48] H. Patel and V. Agarwal, "Matlab-based modeling to study the effects of partial shading on pv array characteristics," *IEEE transactions on energy conversion*, vol. 23, no. 1, pp. 302–310, 2008.
- [49] J. Bastidas, E. Franco, G. Petrone, C. Ramos-Paja, and G. Spagnuolo, "A model of photovoltaic fields in mismatching conditions featuring an improved calculation speed," *Electric Power Systems Research*, vol. 96, pp. 81–90, 2013.
- [50] D. Sharma and G. Purohit, "Analysis of the effect of fill factor on the efficiency of solar pv system for improved design of mppt," in *6th world conference on photo voltaic energy conversion*, 2014.
- [51] V. M. Phap, N. Yamamura, M. Ishida, J. Hirai, K. Yubai, and N. T. Nga, "Modeling and experimental test of grid-tied photovoltaic cell emulating system in the stand-alone mode.," *Journal of Electrical Systems*, vol. 13, no. 2, 2017.
- [52] N. E. Zakzouk, M. A. Elsaharty, A. K. Abdelsalam, A. A. Helal, and B. W. Williams, "Improved performance low-cost incremental conductance pv mppt technique," *IET Renewable Power Generation*, vol. 10, no. 4, pp. 561–574, 2016.
- [53] N. Kumar, I. Hussain, B. Singh, and B. K. Panigrahi, "Framework of maximum power extraction from solar pv panel using self predictive perturb and observe algorithm," *IEEE Transactions on Sustainable Energy*, vol. 9, no. 2, pp. 895–903, 2017.

- [54] A. Kapić, Ž. Zečević, and B. Krstajić, “An efficient mppt algorithm for pv modules under partial shading and sudden change in irradiance,” in *2018 23rd International Scientific-Professional Conference on Information Technology (IT)*, pp. 1–4, IEEE, 2018.
- [55] R. L. Erauskin, A. Gonzalez, G. Petrone, G. Spagnuolo, and J. Gyselinck, “Multi-variable perturb & observe algorithm for grid-tied pv systems with joint central and distributed mppt configuration,” *IEEE Transactions on Sustainable Energy*, 2020.
- [56] S. Bhattacharyya, D. S. K. Patnam, S. Samanta, and S. Mishra, “Steady output and fast tracking mppt (soft mppt) for p&o and inc algorithms,” *IEEE Transactions on Sustainable Energy*, 2020.
- [57] M. Alsumiri, “Residual incremental conductance based nonparametric mppt control for solar photovoltaic energy conversion system,” *IEEE Access*, vol. 7, pp. 87901–87906, 2019.
- [58] A. Chikh and A. Chandra, “An optimal maximum power point tracking algorithm for pv systems with climatic parameters estimation,” *IEEE Transactions on Sustainable Energy*, vol. 6, no. 2, pp. 644–652, 2015.
- [59] E. Moshksar and T. Ghanbari, “A model-based algorithm for maximum power point tracking of pv systems using exact analytical solution of single-diode equivalent model,” *Solar Energy*, vol. 162, pp. 117–131, 2018.
- [60] M. Carrasco, F. Mancilla-David, and R. Ortega, “An estimator of solar irradiance in photovoltaic arrays with guaranteed stability properties,” *IEEE Transactions on industrial electronics*, vol. 61, no. 7, pp. 3359–3366, 2013.
- [61] S. A. Rizzo and G. Scelba, “Ann based mppt method for rapidly variable shading conditions,” *Applied Energy*, vol. 145, pp. 124–132, 2015.
- [62] M. Rolevski and Ž. Zečević, “Mppt controller based on the neural network model of the photovoltaic panel,” in *2020 24th International Conference on Information Technology (IT)*, pp. 1–4, IEEE, 2020.
- [63] M. Nabipour, M. Razaz, S. G. Seifossadat, and S. Mortazavi, “A new mppt scheme based on a novel fuzzy approach,” *Renewable and Sustainable Energy Reviews*, vol. 74, pp. 1147–1169, 2017.
- [64] M. Rakhshan, N. Vafamand, M.-H. Khooban, and F. Blaabjerg, “Maximum power point tracking control of photovoltaic systems: A polynomial fuzzy model-based approach,” *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 6, no. 1, pp. 292–299, 2017.
- [65] T. Esram and P. L. Chapman, “Comparison of photovoltaic array maximum power point tracking techniques,” *IEEE Transactions on energy conversion*, vol. 22, no. 2, pp. 439–449, 2007.
- [66] W. Xiao and W. G. Dunford, “A modified adaptive hill climbing mppt method for photovoltaic power systems,” in *2004 IEEE 35th annual power electronics*

- specialists conference (IEEE Cat. No. 04CH37551), vol. 3, pp. 1957–1963, Ieee, 2004.
- [67] Y. Yang and F. P. Zhao, “Adaptive perturb and observe mppt technique for grid-connected photovoltaic inverters,” *Procedia Engineering*, vol. 23, pp. 468–473, 2011.
 - [68] F. Zhang, K. Thanapalan, A. Procter, S. Carr, and J. Maddy, “Adaptive hybrid maximum power point tracking method for a photovoltaic system,” *IEEE Transactions on Energy Conversion*, vol. 28, no. 2, pp. 353–360, 2013.
 - [69] A. Kapic, Z. Zecevic, M. Radulovic, and B. Krstajic, “A variable step size perturb and observe algorithm for maximum power point tracking,” in *22nd International Scientific-Professional Conference Information Technology*, pp. 6–9, 2017.
 - [70] M. Adly, M. Ibrahim, and H. El Sherif, “Comparative study of improved energy generation maximization techniques for photovoltaic systems,” in *2012 Asia-Pacific Power and Energy Engineering Conference*, pp. 1–5, IEEE, 2012.
 - [71] P. C. Sekhar and S. Mishra, “Takagi–sugeno fuzzy-based incremental conductance algorithm for maximum power point tracking of a photovoltaic generating system,” *IET Renewable Power Generation*, vol. 8, no. 8, pp. 900–914, 2014.
 - [72] F. Liu, S. Duan, F. Liu, B. Liu, and Y. Kang, “A variable step size inc mppt method for pv systems,” *IEEE Transactions on industrial electronics*, vol. 55, no. 7, pp. 2622–2628, 2008.
 - [73] R. M. Corless, G. H. Gonnet, D. E. Hare, D. J. Jeffrey, and D. E. Knuth, “On the lambertw function,” *Advances in Computational mathematics*, vol. 5, no. 1, pp. 329–359, 1996.
 - [74] D. Barry, J.-Y. Parlange, L. Li, H. Prommer, C. Cunningham, and F. Stagnitti, “Analytical approximations for real values of the lambert w-function,” *Mathematics and Computers in Simulation*, vol. 53, no. 1-2, pp. 95–103, 2000.
 - [75] E. Karatepe, M. Boztepe, and M. Colak, “Neural network based solar cell model,” *Energy conversion and management*, vol. 47, no. 9-10, pp. 1159–1178, 2006.
 - [76] M. Karamirad, M. Omid, R. Alimardani, H. Mousazadeh, and S. N. Heidari, “Ann based simulation and experimental verification of analytical four-and five-parameters models of pv modules,” *Simulation Modelling Practice and Theory*, vol. 34, pp. 86–98, 2013.
 - [77] L. L. Jiang and D. L. Maskell, “Automatic fault detection and diagnosis for photovoltaic systems using combined artificial neural network and analytical based methods,” in *2015 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–8, IEEE, 2015.
 - [78] K. Hornik, “Approximation capabilities of multilayer feedforward networks,” *Neural networks*, vol. 4, no. 2, pp. 251–257, 1991.

- [79] F. Almonacid, E. F. Fernandez, A. Mellit, and S. Kalogirou, “Review of techniques based on artificial neural networks for the electrical characterization of concentrator photovoltaic technology,” *Renewable and Sustainable Energy Reviews*, vol. 75, pp. 938–953, 2017.
- [80] R. Castro, “Data-driven pv modules modelling: Comparison between equivalent electric circuit and artificial intelligence based models,” *Sustainable Energy Technologies and Assessments*, vol. 30, pp. 230–238, 2018.
- [81] X. Xu, X. Zhang, Z. Huang, S. Xie, W. Gu, X. Wang, L. Zhang, and Z. Zhang, “Current characteristics estimation of si pv modules based on artificial neural network modeling,” *Materials*, vol. 12, no. 18, p. 3037, 2019.
- [82] T. Khatib, A. Ghareeb, M. Tamimi, M. Jaber, and S. Jaradat, “A new offline method for extracting iv characteristic curve for photovoltaic modules using artificial neural networks,” *Solar Energy*, vol. 173, pp. 462–469, 2018.
- [83] F. Bonanno, G. Capizzi, G. Graditi, C. Napoli, and G. M. Tina, “A radial basis function neural network based approach for the electrical characteristics estimation of a photovoltaic module,” *Applied Energy*, vol. 97, pp. 956–961, 2012.
- [84] M. Rolevski and Ž. Zečević, “Modelovanje fotonaponskog panela primjenom neuralnih mreža,” in *VI Savjetovanje CG KO CIGRE*, 2019.
- [85] A. Chikh and A. Chandra, “Adaptive neuro-fuzzy based solar cell model,” *IET Renewable Power Generation*, vol. 8, no. 6, pp. 679–686, 2014.
- [86] X. Ma, W.-H. Huang, E. Schnabel, M. Köhl, J. Brynjarsdóttir, J. L. Braid, and R. H. French, “Data-driven $i-v$ feature extraction for photovoltaic modules,” *IEEE Journal of Photovoltaics*, vol. 9, no. 5, pp. 1405–1412, 2019.
- [87] Z. Chen, Y. Chen, L. Wu, S. Cheng, P. Lin, and L. You, “Accurate modeling of photovoltaic modules using a 1-d deep residual network based on iv characteristics,” *Energy Conversion and Management*, vol. 186, pp. 168–187, 2019.
- [88] T. Hiyama, S. Kouzuma, T. Imakubo, and T. H. Ortmeyer, “Evaluation of neural network based real time maximum power tracking controller for pv system,” *IEEE Transactions on Energy Conversion*, vol. 10, no. 3, pp. 543–548, 1995.
- [89] I.-S. Cha, J.-G. Choi, G.-J. Yu, M.-w. Jung, H.-L. Baek, and D.-H. Kim, “Mppt for temperature compensation of photovoltaic system with neural networks,” in *Conference Record of the Twenty Sixth IEEE Photovoltaic Specialists Conference-1997*, pp. 1321–1324, IEEE, 1997.
- [90] F. Sedaghati, A. Nahavandi, M. A. Badamchizadeh, S. Ghaemi, and M. Abedinpour Fallah, “Pv maximum power-point tracking by using artificial neural network,” *Mathematical Problems in Engineering*, vol. 2012, 2012.

- [91] R. M. Essefi, M. Souissi, and H. H. Abdallah, "Maximum power point tracking control using neural networks for stand-alone photovoltaic systems," *International Journal of Modern Nonlinear Theory and Application*, vol. 2014, 2014.
- [92] M. Milikić and Ž. Zečević, "Mppt kontroler zasnovan na neuralnim mrežama," in *VI Savjetovanje CG KO CIGRE*, 2019.
- [93] N. Bouarroudj, D. Boukhetala, V. Feliu-Batlle, F. Boudjema, B. Benlahbib, and B. Batoun, "Maximum power point tracker based on fuzzy adaptive radial basis function neural network for pv-system," *Energies*, vol. 12, no. 14, p. 2827, 2019.
- [94] L. Elbaid, A. K. Abdelsalam, and E. E. Zakzouk, "Artificial neural network based maximum power point tracking technique for pv systems," in *IECON 2012-38th Annual Conference on IEEE Industrial Electronics Society*, pp. 937–942, IEEE, 2012.
- [95] J. W. Baek, J. S. Ko, J. S. Choi, S. J. Kang, and D. H. Chung, "Maximum power point tracking control of photovoltaic system using neural network," in *2010 International Conference on Electrical Machines and Systems*, pp. 638–643, IEEE, 2010.
- [96] Ž. Zečević and M. Rolevski, "Neural network approach to mppt control and irradiance estimation," *Applied Sciences*, vol. 10, no. 15, p. 5051, 2020.
- [97] T. A. Ocran, J. Cao, B. Cao, and X. Sun, "Artificial neural network maximum power point tracker for solar electric vehicle," *Tsinghua science and technology*, vol. 10, no. 2, pp. 204–208, 2005.
- [98] M. Di Piazza, M. Luna, M. Pucci, and G. Vitale, "Pv-based li-ion battery charger with neural mppt for autonomous sea vehicles," in *IECON 2013-39th Annual Conference of the IEEE Industrial Electronics Society*, pp. 7267–7273, IEEE, 2013.
- [99] M. C. Di Piazza, M. Pucci, A. Ragusa, and G. Vitale, "A growing neural gas network based mppt technique for multi-string pv plants," in *2010 IEEE International Symposium on Industrial Electronics*, pp. 544–549, IEEE, 2010.
- [100] P. Q. Dzung, H. H. Lee, N. T. D. Vu, *et al.*, "The new mppt algorithm using ann-based pv," in *International Forum on Strategic Technology 2010*, pp. 402–407, IEEE, 2010.
- [101] L. Chun-hua, J. Xu, and Z. Xin-jian, "Study on control strategy for photovoltaic energy systems based on recurrent fuzzy neural networks," in *2009 Fifth International Conference on Natural Computation*, vol. 2, pp. 282–286, IEEE, 2009.
- [102] L. Zhang, Y. Bai, and A. Al-Amoudi, "Ga-rbf neural network based maximum power point tracking for grid-connected photovoltaic systems," 2002.
- [103] B. Marion, A. Anderberg, C. Deline, J. del Cueto, M. Muller, G. Perrin, J. Rodriguez, S. Rummel, T. J. Silverman, F. Vignola, *et al.*, "New data set for

validating pv module performance models,” in *2014 IEEE 40th Photovoltaic Specialist Conference (PVSC)*, pp. 1362–1366, IEEE, 2014.

Prilog

U nastavku je prikazan programski kod realizovan u Matlab-u r2017a, pomoću kojeg su izvršene simulacije opisane u radu. Najprije je dat osnovni kod, a zatim pojedinačne funkcije kojima su definisani NMPPT, P&O i EMPPT algoritmi.

```
close all
clear all
set(groot, 'defaultTextInterpreter', 'latex')
set(groot, 'defaultAxesTickLabelInterpreter', 'latex')
set(groot, 'defaultLegendInterpreter', 'latex')
load .\data\podaciT.mat
load .\data\mreza.mat
net1=net{4};
boje=lines(10);

%%
mi=1.5;gama=50;dV=5;    P=2;  N1=4;
ymaxi=net1.inputs{1}.processSettings{1}.ymax;
ymini=net1.inputs{1}.processSettings{1}.ymin;
ymaxo=net1.outputs{2}.processSettings{1}.ymax;
ymino=net1.outputs{2}.processSettings{1}.ymin;
x maxi=net1.inputs{1}.processSettings{1}.xmax;
x mini=net1.inputs{1}.processSettings{1}.xmin;
x maxo=net1.outputs{2}.processSettings{1}.xmax;
x mino=net1.outputs{2}.processSettings{1}.xmin;

%%
W1=net1.IW{1};
W13=net1.IW{1}(:,3);
W11=net1.IW{1}(:,1);
W2=net1.LW{2};
b1=net1.b{1};

%% inicijalizacija
Sest1(1)=1000;Sest2(1)=15;Sest3(1)=15; Sest4(1)=10;Sest5(1)=10;
v1(1)=30; v2(1)=30; v3(1)=30; v4(1)=20; v5(1)=20;

%%
B=160;
for n=1:B
    if n<=80
        k=31; % bira se kriva 31
        V=VData{k};I=IData{k};s=SData{k}(1);T=TData{k}(1);
        Pm(1)=max(PData{k});
    else
        k=75; % bira se kriva 75
        V=VData{k};I=IData{k};s=SData{k}(1);T=TData{k}(1); dV=0.5;
```

```

    end
Ss(n)=s;
Pm(n)=max(PData{k});

%% NMPPT
i1(n)=interp1(V,I,v1(n)); %struja koja odgovara naponu v(n)
P1(n)=v1(n)*i1(n);
[v1(n+1),Sest1(n+1)]=nmppt(v1(n),i1(n),Sest1(n),net1,T,P,W13,W11,W1,...%
W2,b1,mi,gama,xmaxi,xmini,xmaxo,xmino,ymaxi,ymini,ymaxo,ymino);

%% P&O
i2(n)=interp1(V,I,v2(n)); %struja koja odgovara naponu v(n)
P2(n)=v2(n)*i2(n);
try
    [v2(n+1),dV]=PandO(v2(n),i2(n),v2(n-1),i2(n-1),dV);
catch
    v2(n+1)=v2(n)+1; i2(n)=i2(n)+0.1;
end

%% EMPPT
i3(n)=interp1(V,I,v3(n)); %struja koja odgovara naponu v(n)
P3(n)=v3(n)*i3(n);
[v3(n+1) Sest3(n+1)]=emppt(v3(n),i3(n),TData{k}(1),SData{k}(1));

%% CNNMPPT
i4(n)=interp1(V,I,v4(n)); %struja koja odgovara naponu v(n)
P4(n)=v4(n)*i4(n);
sest4=netc2{N1}([IData{k}(1);VData{k}(1)]);
Sest4(n)=sest4(1);
mpp=netc1{N1}([Sest4(n);TData{k}(1)]);
[v4(n+1)]=mpp(1);
end

hold on
stairs(1:B,P1,'linewidth',0.7,'color',boje(1,:));
stairs(1:B,P2,'linewidth',0.5,'color',boje(2,:));
stairs(1:B,P3,'linewidth',0.7,'color',boje(4,:));
stairs(1:B,P4,'--','linewidth',0.7,'color',[0.5 0.5 0.5]);
stairs(1:B,Pm,'-', 'linewidth',0.7,'color',boje(5,:),'markersize',1);
ylabel('Snaga');
ylim([yl(1) yl(2)+10]);
a=gcf;
ylabel('Snaga [W]');
set(gca,'FontSize',7.2);
grid on
box on
l=legend('NMPPT','P\&O','EMPPT','CNNEST','\$P_{\max}\$');
l.ItemFontSize=[10;18];
l.Position=[0.6838 0.1621 0.2201 0.3484];
legend box on
a=gcf;
xlabel('Diskretno vrijeme[$\it{k}$]')
set(a,'Units','centimeters')
set(a,'position',[1 10 8.88 4.4])

%%

```

```

ax1 = axes('Position',[0.1 0.1 10 10], 'box', 'on');
fig = gcf;
fig.CurrentAxes = ax1;
set(ax1, 'FontSize', 7.2);
ax1.Position=[0.3440 0.5931 0.1493 0.2812];
hold on
stairs(1:B,P1(1:B), 'linewidth', 0.7, 'color', boje(1,:));
stairs(1:B,P2(1:B), 'linewidth', 0.7, 'color', boje(2,:));
stairs(1:B,P3, 'linewidth', 0.7, 'color', boje(4,:));
stairs(1:B,P4, '--', 'linewidth', 0.7, 'color', [0.5 0.5 0.5]);
stairs(1:B,Pm(1:B), '-', 'linewidth', 0.7, 'color', boje(5,:));
xlim([72 B/2])
xticks([72:2:B/2])
ylim([146 146.8])
set(ax1, 'FontSize', 6)

%%
ax2 = axes('Position',[0.1 0.1 10 10], 'box', 'on');
fig = gcf;
fig.CurrentAxes = ax2;
ax2.Position=[0.7304 0.5931 0.1493 0.2812];
hold on
stairs(1:B,P1(1:B), 'linewidth', 0.7, 'color', boje(1,:));
stairs(1:B,P2(1:B), 'linewidth', 0.7, 'color', boje(2,:));
stairs(1:B,P3, 'linewidth', 0.7, 'color', boje(4,:));
stairs(1:B,P4, '--', 'linewidth', 0.7, 'color', [0.5 0.5 0.5]);
stairs(1:B,Pm(1:B), '-', 'linewidth', 0.7, 'color', boje(5,:));
xticks([152:2:B])
xlim([154 B])
ylim([296.2 297.85])
set(ax2, 'FontSize', 6)

%%
print(gcf, '..\Figures\fig7a.eps', '-depsc', '-r0')
figure
stairs(1:B,Sest1(1:B), 'linewidth', 0.7, 'color', boje(1,:));
hold on
stairs(1:B,Sest3(1:B), 'linewidth', 0.7, 'color', boje(4,:));
stairs(1:B,Sest4(1:B), '--', 'linewidth', 0.7, 'color', [0.5 0.5 0.5]);
stairs(1:B,Ss(1:B), 'linewidth', 0.7, 'color', boje(5,:));
ylim([290 750])
a=gcf;
set(a, 'Units', 'centimeters')
set(a, 'position', [1 10 8.88 3.5])
xl=xlabel('Diskretno vrijeme [$\it{k}$]')
ylabel('Iradijansa [$\rm{W/m^2}$]')
set(gca, 'FontSize', 7.2);
grid
l=legend('NI\&I', 'EEST', 'CNNEST', '$G$');
l.Position=[0.6441 0.1985 0.2598 0.3558];
print(gcf, '..\Figures\fig7b.eps', '-depsc', '-r0')

%%
NMPPT
function [v,Sest,Test]=nmppt(v,i,Sest,net,T,P,W13,W11,W1,W2,b1,mi, ...
    gama,xmaxi,xmini,xmaxo,xmino,ymaxi,ymaxo,ymini,ymino)
for m=1:P

```

```

iest=net([Sest;T;v]);
p=[Sest;T;v];
p=(ymaxi-ymini).*(p-xmini)./(xmaxi-xmini)+ymini;
d=(ymaxi-ymini)./(xmaxi(3)-xmini(3)).*(xmaxo-xmino)./(ymaxo-ymino);
izvod= d*sum(W13.*W2'.*(1-tansig(W1*p+b1).^2));
v=v+mi*(iest+v*izvod);
%% estimator iradijanse
e=iest-i;
Sest=Sest-gama*e;
end

%% P&O
function [Vopt dV]=PandO(Vpv,Ipv,Vpret,Ipret,dV)
Vmax=3;
Ppv = Vpv*Ipv;
Ppret=Vpret*Ipret;
Vopt=Vpret;
if (Ppv-Ppret) > 0
    if (Vpv-Vpret) > 0
        Vopt= Vopt + deltaV;
    else
        Vopt = Vopt - dV;
    end
else
    if (Vpv-Vpret) > 0
        Vopt = Vopt - dV;
    else
        Vopt = Vopt + dV;
    end
end
dV=0.5*dV+0.2*abs((Ppv-Ppret)/(Vpv-Vpret));
dV=min(dV,5);
dV=max(dV,0.1);
if (Ipv-Ipret)>0.1*5.456
    dV=Vmax;
end
end

%% EMMPT
function [V,G]=emppt(V,i,T,S)
%% parametri
Tref=298.15;T=T+273.15;Gref=1000;
Vref=41.58; Iscref=5.456;
Iref=5.1;
Rshref=3.09047800000000e+02;
Rs=0.5633; Ns=60;
alfa=0.0016368;
beta=-0.1353;
n=1.1725;
Np=1;
Nser=2;
Egref=1.121;
dg=-2.6770e-04;
Eg=Egref*(1+dg*(T-Tref));
k=physconst('Boltzmann');
q=1.60217646*10^-19;
I0ref=4.8398*10^-12;
Iphref=5.4756;

```

```
Vtref=(n*k*Tref*Ns)/q;
k1=n*k/q;
%% estimacija iradijanse
dI=i-Iref;
dV=V-Vref;
G=Gref*(Iscref+dI)./(Iscref-alfa/beta*(Rs*dI+dV));
%% update parametara kola
Iph=Np*[Iphref+alfa*(T-Tref)]*G/Gref;
I0=Np*I0ref*(T/Tref)^3*exp(1/k1*(Egref/Tref-Eg/T));
Vt=Vtref*(T/Tref)*Nser;
Rsh=Rshref*(Gref/G);
%% racunanje gradijenta
g=Rs*I0*Rsh*exp(Rsh*(Rs*Iph+Rs*I0+V)/Vt/(Rs+Rsh))/Vt/(Rs+Rsh);
I=-V/(Rs+Rsh)+Rsh*(I0+Iph)/(Rs+Rsh)-lambertw(g)*Vt/Rs;
%%
g1=1./(g+exp(lambertw(g)));
g2=Rs*I0*Rsh^2*exp(Rsh*(Rs*Iph+Rs*I0+V)/Vt/(Rs+Rsh))/(Vt^2*(Rs+Rsh)^2);
V=V+1.5*(I-V*[1/(Rs+Rsh)+Vt/Rs*g1*g2]);
%%
function y=lambert(x)
eps=0.4586887;
y=(1+eps)*log(6/5*x./log(12/5*x./log(1+12/5*x)))-...
    eps*log(2*x./log(1+2*x));
if x<1e-8
    y=0;
end
end
end
```