

Algoritem za izračun napovedi trenutne moči sončne elektrarne s pomočjo nevronske omrežje

MIHAEL SKORNŠEK & GORAZD ŠTUMBERGER

Povzetek Delo obravnava spremljanje in primerjavo obratovalnih lastnosti sončnih elektrarn. Vsa odstopanja v delovanju lahko spremljamo z dodatnimi meritvami na elektrarni, kot sta sončno obsevanje in temperatura celice. Na podlagi polletnih meritev parametrov delovanja je s pomočjo umetnega nevronskega omrežja v programskem paketu Matlab pripravljen algoritem za izračun napovedane moči sončne elektrarne v danem trenutku, s katerim lahko ovrednotimo pravilno delovanje le-te. Omenjeni algoritem predstavlja nadgradnjo sistema za spremljanje obratovanja sončne elektrarne. Večja razlika med izmerjenimi in z algoritmom določenimi trenutnimi izhodnimi močmi sončne elektrarne kaže na neustrezno delovanje posameznih elementov sončne elektrarne in potrebo po podrobnejšem preverjanju.

Ključne besede: • algoritem • napovedovanje • trenutna moč • sončna elektrarna • nevronska omrežje •

NASLOV AVTORJEV: mag. Mihael Skornšek, Gorenje d.d., Partizanska 12, 3320 Velenje, e-pošta: mihael.skornsek@gorenje.com. dr. Gorazd Štumberger, redni profesor, Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Smetanova ulica 17, 2000 Maribor, Slovenija e-pošta: gorazd.stumberger@um.si.

<https://doi.org/10.18690/978-961-286-071-4.23>

ISBN 978-961-286-071-4

© 2017 Univerzitetna založba Univerze v Mariboru

Dostopno na: <http://press.um.si>.

Algoritem for Predicting Solar Power Plant Output Power with an Artificial Neural Network

MIHAEL SKORNŠEK & GORAZD ŠTUMBERGER

Abstract This work deals with the comparison of operating properties of photovoltaic power plants. All derogations in the operation of photovoltaic power plant can be monitored with additional measurements of solar irradiation and temperature of photovoltaic cells. Based on data acquired during six months operation of discussed photovoltaic power plant an Artificial Neural Network (ANN) has been built in order to predict output power of the power plant. The ANN complements the already existing monitoring system. When the difference between the ANN predicted and measured output power of the photovoltaic power plant is too high, a detail check of the power plant components is required.

Keywords: • algoritem • prediction • output power • solar power plant • artificial neural network •

CORRESPONDENCE ADDRESS: Mihael Skornšek, M.S., Gorenje d.d., Partizanska 12, 3320 Velenje, e-mail: mihael.skornsek@gorenje.com. Gorazd Štumberger, Ph.D., Full Professor, Faculty of Electrical Engineering and Computer Science, Smetanova ulica 17, 2000 Maribor, Slovenia e-mail: gorazd.stumberger@um.si.

<https://doi.org/10.18690/978-961-286-071-4.23>

ISBN 978-961-286-071-4

© 2017 University of Maribor Press

Available at: <http://press.um.si>.

1 Uvod

Cilj dela je predstaviti metodologijo in potrebno opremo za primerjavo delovanja omrežnih sončnih elektrarn pri različnih pogojih obratovanja. Praktično vsaka elektrarna potrebuje nadzorni sistem, ki spremlja delovanje elektrarne, predvsem pa pravočasno javlja napake oz. odstopanja v delovanju. Nekatere okvare je zaradi njihovega obsega lažje zaznati, težave pa nam predstavljajo manjša odstopanja.

Z na novo razvitim algoritmom želimo nadgraditi nadzorni sistem tako, da bo lahko zaznal manjša odstopanja brez nepotrebne javljanja okvar. Takšen sistem deluje na osnovi primerjave dejanske moči z napovedano vrednostjo moči elektrarne v nekem trenutku. Napovedano vrednost moči določimo na podlagi sprotnega merjenja sončnega obsevanja in temperature celice. V kolikor ta vrednost ni realna, prihaja do nepotrebne javljanja napak, ki jih sproži nadzorni sistem. Za napoved izhodne moči sončne elektrarne uporabimo algoritem na osnovi umetnega nevronskega omrežja ustrezne strukture. Za učenje umetnega nevronskega omrežja uporabimo arhiv meritev sončne elektrarne, ki vsebuje podatke o temperaturi sončnih modulov, gostoti moči sončnega sevanja in dejanski izhodni moči sončne elektrarne. Na tak način naučeno umetno nevronske omrežje lahko zagotovi precej dobro napoved izhodne moči sončne elektrarne.

V nadaljevanju bo predstavljen izračun napovedane izhodne moči sončne elektrarne na osnovi linearne modela, ki izhodno moč elektrarne določi na osnovi trenutne vrednosti obsevanja in temperature fotonapetostnega modula. Tako izračunane vrednosti izhodne moči sončne elektrarne bodo primerjane s tistimi, ki jih dobimo iz predlaganega algoritma na osnovi umetnega nevronskega omrežja in rezultati meritev. Predlagani, na umetnem nevronskega omrežju temelječ, algoritem napovedi izhodne moči sončne elektrarne je mogoče s pridom uporabiti pri spremljanju obratovanja sončne elektrarne. Velikost odstopanja med napovedano in izmerjeno izhodno močjo je mogoče uporabiti pri diagnostiki obratovanja sončne elektrarne in ugotavljanju sicer skritih napak.

2 Pregled opazovanih testnih fotonapetostnih polj

Analiza obratovanja sončnih elektrarn je bila izvedena na t. i. testnih fotonapetostnih (FN) poljih [1]. Sončno elektrarno sestavlja več takšnih polj za katera je značilno, da so zgrajena iz enakih komponent in da so enakih moči, razlikujejo pa se po načinu oz. naklonu namestitve fotonapetostnih modulov, nekatera pa tudi po tipu uporabljenih razsmernikov.

Tabela 23.1: Seznam fotonapetostnih (FN) testnih polj

Oznaka	Moč [W]	Naklon modulov	Usmerjenost modulov
FN1	9.870	0°	0° (J)
FN2	9.870	25°	0° (J)
FN3	9.870	34°	0° (J)
FN4	9.870	7° (J)	0° (J)
FN5	9.870	-7° (S)	0° (J)
FN6	9.870	90°	0° (J)
FN7	9.870	sledenje soncu	sledenje soncu
FN8	9.870	20°	sledenje soncu
FN9	9.870	sledenje soncu	0° (J)
FN10	9.870	20° (talna postavitve)	0° (J)

Vsa FN polja so nameščena na enaki mikrolokaciji, saj so tako omogočeni čim bolj enaki pogoji obratovanja za namene analiz in primerjav. Za vsako od njih se izvajajo naslednje meritve:

- **Za vsako FN testno polje:**
 - trenutna moč,
 - dnevna proizvedena energija,
 - sončno obsevanje na ravnino FN polja,
 - temperatura celic FN modulov.

- **Okoljski parametri:**
 - temperatura okolice,
 - hitrost in smer vetra poleg,
 - količina padavin,
 - obsevanje na horizontalno ploskev,
 - globalno obsevanje – piranometer.

Vsi ti podatki se odčitavajo v poljubno dolgih intervalih, ki jih je mogoče nastaviti, in se shranjujejo v bazo ter hkrati prikazujejo na centralnem nadzornem sistemu. Na zahtevo je mogoče beležiti še ostale parametre, ki jih merijo razsmerniki sami. Podatki v bazi so tako dostopni za nadaljnje analize in primerjave obratovanja.

3 Validacija trenutne moči sončne elektrarne

Obratovalni pogoji sončne elektrarne se tekom daljšega obratovanja spreminjajo. Vzroki za to so lahko staranje celic fotonapetostnih modulov, trdovratnejša umazanija na njih, okvare na električnih napeljavah ali drugih elementih, spremembe na razsmernikih itd. Vsa takšna stanja povzročajo določeno izgubo moči in s tem delno zmanjšanje proizvedene električne energije. Medtem ko večje okvare lažje zaznamo (zaradi občutnega padca moči oz. proizvedene energije), je stanja z manjšimi okvarami težje zaznati, kljub temu pa so lahko na dolgi rok vzrok večjega izpada proizvodnje električne energije.

Nadzorni sistem sončne elektrarne na podlagi podatkov iz razsmernikov seveda z neko natančnostjo javlja odstopanja, npr. izpad enega niza modulov, občutno zmanjšanje moči enega niza, okvaro razsmernika ali pa samo napako v komunikaciji. Tak sistem pa odpove v primeru, ko gre za odstopanja le nekaj odstotkov ali pa v primeru, ko je celotno polje modulov pod vplivom umazanije, nadzorni sistem pa vrši javljanje okvar samo na podlagi medsebojnih primerjav (na nivoju posameznega niza ali na nivoju posameznega MPPT vhoda razsmernika).

Naprednejši nadzorni sistemi vključujejo tudi senzor direktnega obsevanja na ravnino modulov, na podlagi katerega se izvede primerjava med trenutno močjo, odčitano iz razsmernika, ter napovedano močjo, izračunano na podlagi obsevanja. Tudi tukaj se pojavljajo težave pri računanju, saj so v določenih primerih odstopanja prevelika, kljub temu da elektrarna obratuje normalno brez okvar ali umazanije na modulih. V takšnih primerih prihaja do lažnega javljanja odstopanj, česar pa si ne želimo.

3.1 Analitični izračun napovedane moči fn polja

Večina komercialno dostopnih nadzornih sistemov vrši kontrolo izhodne moči elektrarne na podlagi izmerjenega obsevanja in temperature celice, le-ta pa je v veliko primerih izračunana. Na podlagi parametrov o modulih, ki jih poda proizvajalec, lahko izračunamo trenutno moč [3] z linearnim preračunom trenutnega obsevanja na STC, potem pa dobljeno vrednost korigiramo še s temperaturnim koeficientom moči. Za izračun moči z izmerjeno temperaturo uporabimo izraz (1), z izračunano temperaturo [4] pa (2).


$$P_{imT} = \frac{G_a}{1000} \cdot P_{inst} \cdot (1 - \gamma(T_{mT} - T_{STC})) \quad (1)$$

$$P_{iiT} = \frac{G_a}{1000} \cdot P_{inst} \cdot (1 - \gamma(T_{iT} - T_{STC})) \quad (2)$$

pri tem so:

- P_{imT} izračunana trenutna moč elektrarne na osnovi izmerjene temperature celice [kW],
- P_{iiT} izračunana trenutna moč elektrarne na osnovi izračunane temperature celice [kW],
- G_a trenutno obsevanje [W/m^2],
- P_{inst} inštalirana moč elektrarne [kW],
- γ temperaturni koeficient moči [$1/^\circ C$],
- T_{mT} izmerjena temperatura modula oz. celice [$^\circ C$],
- T_{iT} izračunana temperatura modula oz. celice [$^\circ C$],
- T_{STC} temperatura modula oz. celice pri STC [$^\circ C$].

Na podlagi tabelarnih podatkov smo preverili točnost opisanega algoritma za različna FN polja. Rezultate smo preverili na podlagi meritev v štirih dneh – dveh sončnih in dveh delno oblačnih, enkrat v poletnem in drugič v zimskem času. Ker so uporabljeni razsmerniki enakega tipa, imajo enak t.i. euro izkoristek [2], kar je bil tudi pogoj o enakih lastnostih primerjanih FN testnih polj.



Slika 23.1: Prikaz napovedane in izračunane moči za FN polje 25°

Rezultati za FN polje z naklonom modulov 25° so prikazani na sliki 1. Z rdečo črto je prikazana izračunana moč na osnovi izračunane temperature celice (P_{iT}), z modro pa na osnovi dejansko izmerjene temperature celice (P_{imT}). Z zeleno je prikazana pričakovana (napovedana) moč (P_P), ki je dejansko izmerjena trenutna moč. Izračunana vrednost temperature celice daje v določenih dnevih precej slab rezultat, nekoliko bolje pa se obnese izračun z merjeno temperaturo. Podobno obnašanje opazimo na FN poljih z drugimi nakloni, in če povzamemo rezultate iz prakse ugotovimo, da so takšne meritve za diagnosticiranje manjših odstopanj napovedane moči manj uporabne, saj je rezultat preveč odvisen od drugih dejavnikov, kot so način montaže modulov, hitrost vetra, konstrukcijska zasnova modulov itd. Glede na to, da imamo na voljo velik arhiv meritev, bomo poizkusili poiskati natančnejši algoritem za izračun napovedane moči elektrarne, s katerim bomo lahko diagnosticirali tudi manjša odstopanja v moči oz. proizvodnji električne energije sončne elektrarne.

3.2 Algoritem za napoved moči sončne elektrarne na osnovi umetnega nevronskega omrežja

Ugotovili smo, da metoda računanja pričakovane moči oziroma napoved moči na podlagi sončnega obsevanja in temperature celice z analitičnim modelom ne daje dovolj dobrega rezultata za različne konfiguracije sončnih elektrarn skozi celo leto, ne glede na to, ali smo temperaturo celice merili ali izračunali. V kolikor imamo na voljo dovolj veliko bazo izmerjenih vrednosti obratovalnih parametrov sončnih elektrarn, lahko algoritem za izračun napovedane moči izvedemo s pomočjo umetnega nevronskega omrežja, kot je prikazano v nadaljevanju. Arhiv teh podatkov, ki so izmerjeni med normalnim delovanjem elektrarne, ko na njej ni okvar ali drugih dejavnikov, ki bi vplivali na njeno izhodno moč, lahko uporabimo za iskanje funkcije za izračun napovedane moči oziroma napovedi proizvodnje v realnem času.

Osnove delovanja umetnih nevronskega omrežja izhajajo iz modela aktivnosti človeških možganov. Človekova obdelava informacij poteka preko vzbujanj med nevroni (živčnimi celicami). Človekov osrednji živčni sistem je sestavljen iz več milijard nevronov. S stališča obdelave informacij lahko obravnavamo vsak nevron kot enostaven procesor [5].

Učenje in testiranje sta praktično najpomembnejša dela ustvarjanja nevronskega omrežja. Prvi korak učenja je vnos vprašanj z znanimi odgovori. Sledi primerjava odgovora omrežja z znanimi pravilnimi odgovori (testiranje). Nato se prilagajajo uteži povezav med posameznimi nevroni, dokler omrežje ne da pravega odgovora. Postopek se ponavlja tako dolgo, dokler omrežje ni ustrezno naučeno. Cikel učenja se izvaja, dokler niso zadoščene zahteve določenega kriterija (maksimalni čas učenja, maksimalni pogrešek, maksimalno število ciklov ...). Pričakovani rezultat je umetno nevronskega omrežja, ki lahko odgovarja tudi na vprašanja z neznanimi odgovori. Za preizkušanje pravilnosti sledijo testi z drugimi vprašanji, na katera so odgovori že znani.

Za izračun napovedane moči elektrarne s pomočjo nevronskega omrežja bomo za fazo učenja omrežja uporabili nabor polletnih meritev za vseh šest FN testnih polj s fiksnimi nakloni modulov in tako poiskali povezavo – funkcijo med vhodnimi podatki ter napovedano močjo, ki jo bomo potem preizkusili na posameznih FN testnih poljih. Najprej je potrebno pripraviti bazo podatkov, imenovano učni vzorci.

To so vhodni podatki za določitev nevronskega omrežja. V našem primeru smo kot razpoložljive učne podatke izbrali:


- temperaturo celice [$^{\circ}\text{C}$],
- direktno obsevanje [W/m^2],
- globalno obsevanje [W/m^2].

Ciljne vrednosti so bile izmerjene vrednosti izhodne moči:

- moč elektrarne [kW].

Kreiranje in konfiguracija omrežja

Po tem, ko je bilo nevronske omrežje kreirano (slika 23.2), mora biti konfigurirano in naučeno. V našem primeru vsebuje nevronske omrežje tri vstopne nevrone, 5 skritih nevronov ter en izstopni nevron.

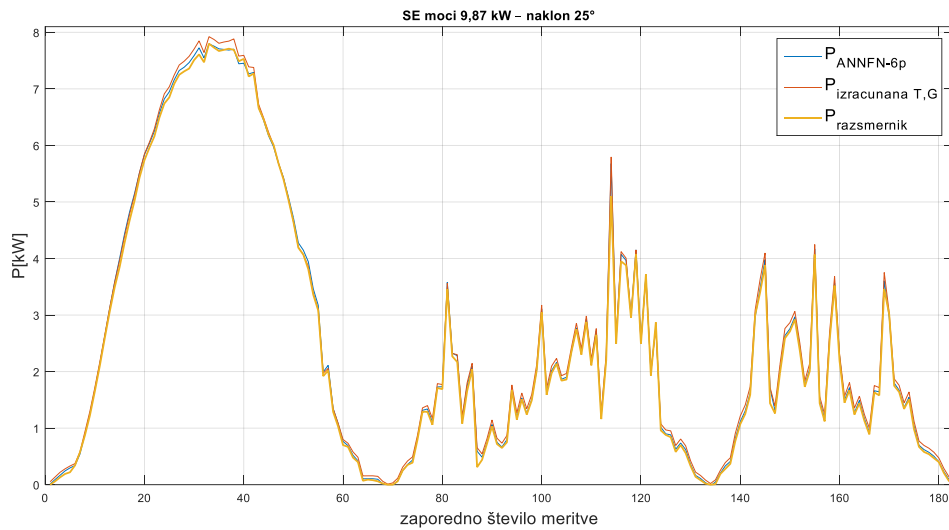


Slika 23.2: Model nevronskega omrežja v Matlab-u


Vstopni nevрони predstavljajo izbrane izmerjene vrednosti: direktno in globalno obsevanje, temperaturo celice. Srednja raven je t. i. skrita raven, katere velikost je bila s preizkušanjem optimizirana na pet nevronov. Zadnji ali izstopni nevron pa je izhodna moč sončne elektrarne – ciljna vrednost. Vsi ti podatki so izmerjeni takrat, ko elektrarna deluje brez okvar, na modulih oz. referenčni celici za merjenje obsevanja pa ni umazanij. Konfiguracija vključuje takšno zasnovo omrežja, ki je združljiva s problemom, kot je opredeljeno v vzorčnih podatkih.

3.3 Preizkus napovedovanja trenutne moči s pomočjo nevronskega omrežja na različnih fn testnih poljih

Na slikah 23.3 in 23.4 je prikazan potek moči za FN polje 25° , in sicer za tri naključne dni. Z rumeno ($P_{razsmernik}$) je prikazan potek izmerjene moči razsmernika – ciljne vrednosti, z rdečo ($P_{izracunana T,G}$) potek moči, izračunane analitično na podlagi obsevanja in temperature celice, ter z modro ($P_{ANNFN-6p}$) potek moči, izračunane s pomočjo nevronskega omrežja. Medtem ko v delno oblačnih dneh opazimo manjša odstopanja v vrednostih, pa je v območju večjih moči (sončen dan) z nevronskega omrežja določena moč zelo blizu izmerjeni.



Slika 23.3: Prikaz izračunanih in izmerjenih vrednosti moči za FN polje 25°




Slika 23.4: Prikaz izračunanih in izmerjenih vrednosti moči za FN polje 25° – detajl

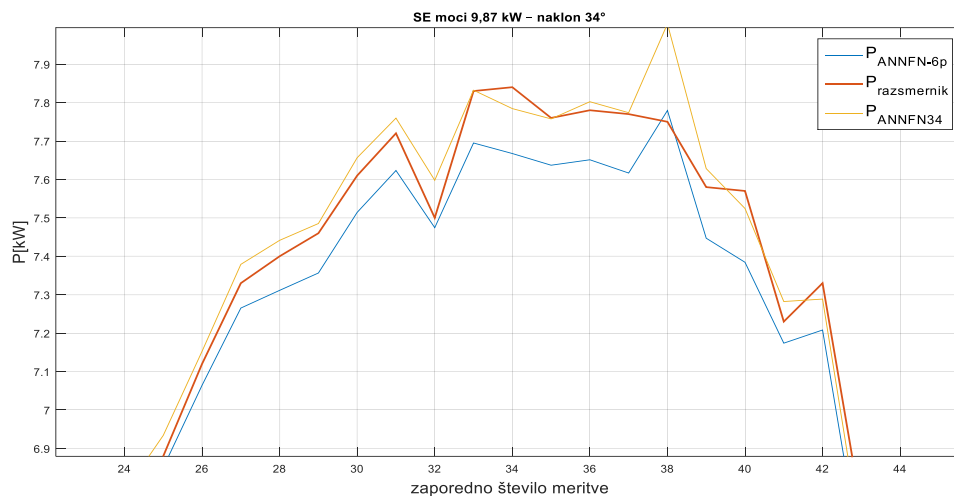
Na podlagi obsevanja in temperature celice analitično izračunana izhodna moč daje v območju večjih moči prevelike vrednosti. To ima za posledico nepotrebno javljanje sistema za spremljanje delovanja elektrarne (monitoring) o prevelikih odstopanjih med napovedano (izračunano) in izmerjeno izhodno močjo elektrarne.

Obravnavali smo izračun napovedane moči elektrarne na osnovi prenosne funkcije, ki je bila izračunana s pomočjo nevronskega omrežja na bazi polletnih podatkov za FN polja z različnimi nakloni. Takšno nevronskega omrežje je do neke mere univerzalno, saj ga lahko uporabimo na sončnih elektrarnah z različnimi nakloni. V nadaljevanju si bomo ogledali še nekaj primerov, ko je funkcija za izračun napovedane moči dobljena s pomočjo nevronskega omrežja, učni podatki nevronskega omrežja pa so z meritvami pridobljeni samo za opazovano FN polje in ne za več polj.

Tokrat opazujemo, kateri izračun napovedane moči s pomočjo nevronskega omrežja bolje opravi svoje delo: tisti, ki ima učne vzorce na osnovi podatkov za več FN polj ($P_{ANNFN-6p}$), ali tisti, katerega osnova so podatki samo opazovanega polja ($P_{ANNFN34}$). V nadaljevanju so na slikah poteki moči $P_{ANNFN-6p}$ prikazani z modro, $P_{ANNFN34}$ z rumeno in $P_{razsmernik}$ (ciljna vrednost) z rdečo barvo.



Slika 23.5: Prikaz izračunanih in izmerjenih vrednosti moči za FN polje 34°



Slika 23.6: Prikaz izračunanih in izmerjenih vrednosti moči za FN polje 34° – detajl

Primerjavo (slika 23.5) pogledamo za polje z naklonom 34° za iste tri opazovane dni kot v prejšnjem primeru. Pregled detajla na sliki 6 nam pokaže boljše ujemanje napovedane moči s ciljno v primeru izračuna z nevronskega omrežja z učnimi podatki polja modulov z naklonom 34°.

4 Sklep

V delu smo predstavili medsebojno primerjavo delovanja elektrarn z dvema omenjenima vrstama razsmernikov, tako v normalnih pogojih obratovanja, kot tudi v primeru delno senčenih modulov. Ugotovili smo, da lahko v delovanju prihaja do manjših, komaj zaznavnih razlik ali

pa večjih, lažje opaznih. Te ugotovitve, izoblikovane na podlagi analize izmerjenih obratovalnih parametrov dejanske elektrarne, so bile podlaga za nadaljnje korake, ko smo iskali algoritem za izračunavanje napovedi pričakovane izhodne moči elektrarne v danem trenutku, na podlagi meritev okoljskih parametrov.

Na podlagi meritev obsevanja in temperature celice nadzorni sistemi napovedujejo izhodno moč elektrarne, ki bi jo glede na inštalirano moč modulov morala v tistem trenutku dosegati. V praksi pa se izkaže, da takšna napoved pogosto ni dovolj natančna, zaradi česar prihaja do nepotrebne javljanja nadzornega sistema o nepričakovanem zmanjšanju izhodne moči elektrarne, kar predstavlja nenormalno obratovalno stanje.

Če se z dodatnimi meritvami prepričamo, da elektrarna v nekem obdobju obratuje brez okvar, lahko takšno bazo izmerjenih podatkov uporabimo v algoritmu za napovedovanje izhodne moči fotonapetostnega polja, ki temelji na uporabi umetnih nevronskega omrežij. Pri tem so vhodni podatki pri učenju nevronskega omrežja informacije o pogojih obratovanja, ciljna vrednost pa je izmerjena izhodna moč fotonapetostnega polja elektrarne. Naučeno umetno nevronske omrežje lahko v nadaljevanju uporabljamo za napovedovanje izhodne moči posameznega fotonapetostnega polja ali celotne sončne elektrarne, ob upoštevanju trenutnih pogojev obratovanja. Slednji so pogosto podani v obliki merjenega obsevanja in temperature celic fotonapetostnih modulov.

Umetna nevronska omrežja za različna fotonapetostna testna polja so bila učena z različnimi nabori učnih podatkov. Pri tem smo enkrat uporabili nabor merjenih podatkov s fotonapetostnih testnih polj z različnimi nakloni, drugič pa samo podatke merjene na opazovanem testnem polju. Predlagan način napovedi izhodne moči posameznih polj sončne elektrarne z ustrezno naučenimi umetnimi nevronskega omrežji omogoča uporabo podatkov preteklega obratovanja elektrarne za učenje umetnega nevronskega omrežja, ki omogoča bolj točno napovedovanje izhodne moči elektrarne. Slednje je s pridom mogoče uporabiti v sistemu za nadzor delovanja elektrarne. Pri tem se lahko nevronske omrežje tudi sproti uči in se tako dinamično prilagaja spreminjanju obratovalnih pogojev in staranju posameznih elementov elektrarne.

Literatura in viri

- [1] M. Skornšek, *Primerjava obratovalnih lastnosti fotonapetostnih sistemov z mikrorazsmerniki in klasičnimi razsmerniki*, magistrsko delo, Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, 2016.
- [2] İlker Ongun, Engin Özdemir, *Weighted efficiency measurement of PV inverters: introducing $\eta_{IZMİR}$* , Journal of optoelectronics and advanced materials, 15, str. 550–554, 2013.
- [3] E. Skoplaki, J.A. Palyvos, *On the temperature dependence of photovoltaic module electrical performance: A review of efficiency/power correlations*, Solar Energy 83, str. 614–624, 2009
- [4] C. González-Morán, P. Arbolea, D. Reigosa, G. Díaz, J. Gómez-Aleixandre, *Improved model of photovoltaic sources considering ambient temperature and solar irradiation*, Sustainable Alternative Energy (SAE), IEEE PES/IAS Conference on, str. 1–6, 2009.
- [5] D. Donlagić s soavtorji, *Osnove snovanja mehkih (fuzzy) regulacij*, Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, 1995.