

## DIRBTINIŲ NEURONŲ TINKLO TAIKYMAS DIDŽIAUSIOS GALIOS TAŠKO SAULĖS ELEMENTUOSE SEKIMO ALGORITME

Modestas Pikutis

Vilniaus Gedimino technikos universitetas  
El. paštas [modestas.pikutis@dok.vgtu.lt](mailto:modestas.pikutis@dok.vgtu.lt)

**Santrauka.** Mokslininkai intensyviai ieško būdų, kaip pagerinti saulės elementų naudingumo koeficientą, kuris rinkoje paplitusiuose elementuose siekia 20 %. Kai didžiausios galios taškui (DGT) sekti naudojamas lėtas valdiklis arba valdiklis, nesugebantis palaikyti saulės elemento režimo didžiausios galios taške – saulės jėgainės našumas labai sumažėja ir dalis saulės energijos, krentančios į saulės modulį, lieka nepanaudota. Nuolat kuriami įvairūs didžiausios galios taško sekimo algoritmai, tačiau dauguma jų dirba lėtai arba daro klaidas. Siekiant padidinti valdiklio efektyvumą, literatūroje vis dažniau minimas dirbtinių neuronų tinklų (DNT) taikymas DGT sekimo procese. Darbe sukurtas saulės jėgainės modelis, kuriame panaudotas didžiausios galios taškui sekti savaimė besimokantis dirbtinių neuronų tinklas, veikiantis kartu su *IncCond* algoritmu, ir sudarytas valdymo algoritmas. Saulės jėgainės modelis įgyvendintas *Matlab/Simulink* terpėje.

**Reikšminiai žodžiai:** dirbtinių neuronų tinklas, saulės elementai, didžiausios galios taško sekimas.

### Įvadas

Per tris valandas į žemės paviršių patenka tiek saulės energijos, kiek žmonija sunaudoja per visus metus. Nepaisant tokio didelio energijos srauto, tik nedidelė jo dalis yra naudojama kaip atsinaujinantis energijos šaltinis. Dalis šios energijos pasitelkus saulės kolektorius panaudojama šiltam vandeniui ruošti. Kita dalis fotovoltinėse jėgainėse paverčiama elektros energija.

Saulės energijos, paverčiamos elektros energija, kiekis pirmiausiai priklauso nuo pačių saulės elementų (SE) tipo. Mažiausią naudingumo koeficientą turi amorfiniai, plonasluoksniai, polikristaliniai, hibridiniai SE. Šiuo metu vieni brangiausių, tačiau efektyviausiai gebančių paversti saulės energiją elektros energija, yra monokristaliniai saulės elementai. Kiekvienais metais SE naudingumo koeficientas didinamas. Tačiau kol kas plačiai taikomi saulės elementai, kurių naudingumo koeficientas neviršija 20 %.

Kitas labai svarbus veiksnys, lemiantis saulės elementų efektyvumą, yra neprognozuojamai besikeičiančios ir niekuomet neatsikartojančios oro ir saulės spinduliavimo sąlygos. Dėl šios priežasties negalime iš anksto atskirais laiko intervalais numatyti saulės elementų apkrovos.

Saulės jėgainė (SJ) dirba efektyviausiai, kai saulės modulių (SM) apkrova priderinama prie aplinkos sąlygų, tai yra sekamos didžiausios galios. Taigi itin didelę įtaką turintis veiksnys, verčiant saulės energiją į elektros energiją,

yra didžiausios galios taško sekimo (DGTS) įrenginys. Nuo šio įrenginio panaudoto sekimo algoritmo priklauso, kaip greitai ir kaip tiksliai bus pasiektas atitinkamu laiko momentu didžiausios galios taškas saulės modulyje. Būtina įvertinti tai, kad saulės modulio didžiausios galios taško priklausomybė nuo saulės energijos srauto bei aplinkos temperatūros yra netiesinė ir eksploatacijos metu keičiasi. Todėl nėra galimybės iš anksto nurodyti saulės modulio varžos vertes atitinkamomis sąlygomis. Tai apsunkina DGT sekimo algoritmų darbą.

Kadangi šiuo metu saulės elementai yra brangūs, o jų efektyvumo koeficientas yra nedidelis, todėl yra labai svarbu kaip įmanoma tiksliau ir greičiau pasiekti DGT. Šiam tikslui yra naudojami įvairūs sekimo algoritmai, ieškoma naujų sekimo metodų. Tačiau dauguma sekimo algoritmų yra gana lėti arba netikslūs.


Dėl sugebėjimo spręsti netiesines lygtis literatūroje vis dažniau minimi ir kaskart randantys vis naujas pritaikymo galimybes yra dirbtinių neuronų tinklai. Dirbtinių neuronų tinklai naudojami ir saulės energetikoje.

Darbe siūloma naudoti dirbtinių neuronų tinklą kaip papildomą įrankį sekti DGT. Apmokytas DNT galėtų greitai ir tiksliai aptikti didžiausios galios tašką saulės jėgainėse bei neprarasti itin svarbios elektros energijos. Šiam tyrimui naudojamas matematinis saulės jėgainės modelis su *IncCond* DGT sekimo algoritmu ir dirbtinių neuronų tinklas.

## Apėjimo diodo įtaka

Valdiklio darbą saulės jėgainėse apsunkina saulės moduliuose esantys apėjimo diodai. Apėjimo diodai SM skirti apsaugoti saulės elementams nuo perkaitimo, kai dalis modulio dirba šešėlyje. Kita apėjimo diodo paskirtis yra padidinti saulės jėgainės našumą, esant iš dalies apšviestam saulės moduliui. Taikant apėjimo diodą modulis gali dirbti apeidamas šešėlyje esančius saulės elementus ir taip išlaikydamas geresnes energetines charakteristikas (Díaz-Dorado *et al.* 2010). Nesant apėjimo diodo ir daliai modulio patekus į šešėlį, visas modulis dirba mažiau apšviestų elementų darbo režimu. Dėl šios priežasties saulės jėgainės našumas labai sumažėja ir dalis saulės energijos lieka nepanaudota.

Minėti apėjimo diodo trūkumai ir privalumai yra matomi 1 pav. Čia pavaizduotos dviejų saulės modulių darbo charakteristikos, kai viename jų yra apėjimo diodas, o kitame – nėra. Brūkšninė linija atvaizduoja galios charakteristiką, esant skirtingam saulės galios srautui. Pirmoji brūkšninė kreivė yra galios charakteristika, kai į du saulės modulius SM1 ir SM2 patenka vienodas saulės galios srautas  $SM1 = SM2 = 1000 \text{ W/m}^2$ . Antroji kreivė apibūdina atvejį, kai į SM1 modulį patenka  $1000 \text{ W/m}^2$ , o į SM2 –  $600 \text{ W/m}^2$ . Trečioji charakteristika apibūdina saulės jėgainės darbą, kai į SM1 modulį patenka  $1000 \text{ W/m}^2$ , o į SM2 –  $200 \text{ W/m}^2$  saulės galios srautas. Išsitiesinės linijos yra saulės modulių voltamperinių charakteristikų šeima. Ketvirtoji kreivė apibūdina atvejį, kai į abu saulės modulius SM1 ir SM2 patenka vienodas saulės galios srautas  $1000 \text{ W/m}^2$ . Penktoji kreivė atitinka voltamperinę charakteristiką, kai pirmas saulės modulis (SM1) apšviestas  $1000 \text{ W/m}^2$ , o antras (SM2) –  $600 \text{ W/m}^2$ . Šeštoji kreivė apibūdina atvejį, kai SM1 –  $1000 \text{ W/m}^2$ , o SM2 –  $200 \text{ W/m}^2$ . Juodas taškas žymi kiekvienos charakteristikos didžiausios galios tašką.



1 pav. Dviejų saulės modulių su apėjimo diodais 1–3 galios ir 4–6 voltamperinės charakteristikos

Fig. 1. 1–3 power and 4–6 current-voltage characteristics of two solar modules with bypass diodes

Iš galios charakteristikų matyti, kad krintant skirtingiems saulės galios srautams į atskirus saulės modulius atsiranda keli lokalūs DGT. Kai apšvietimo lygio skirtumas į atskirus saulės modulius yra nedidelis, didesnė galia SJ gaunama ties dviejų modulių įtampų suma. Kai saulės galios srautas, tenkantis antrajam moduliui, siekia tik  $200 \text{ W/m}^2$ , akivaizdu, kad jėgainė dirba efektyviau tik ties vieno SM išėjimo įtampa. Dirbant saulės jėgainei, charakteristikos vietos parinkimą, tai yra darbo įtampą, vykdo DGT sekimo algoritmas. Įprasti DGT sekimo algoritmai dažnai nesugeba atskirti globalaus ir lokalaus didžiausios galios taškų. Sekimo algoritmas, pasilikęs dirbti lokaliame didžiausios galios taške, padaro visos saulės jėgainės darbą neefektyvų, nes dalis krintančios saulės energijos nepanaudojama. Dalis žinomų sekimo algoritmų, patekę į vieną iš lokalių DGT, nesugeba iš jo išėiti ir lieka visam laikui. Tokiu atveju sistemą tenka perkrauti ir prarasti nemažai laiko ir saulės energijos.

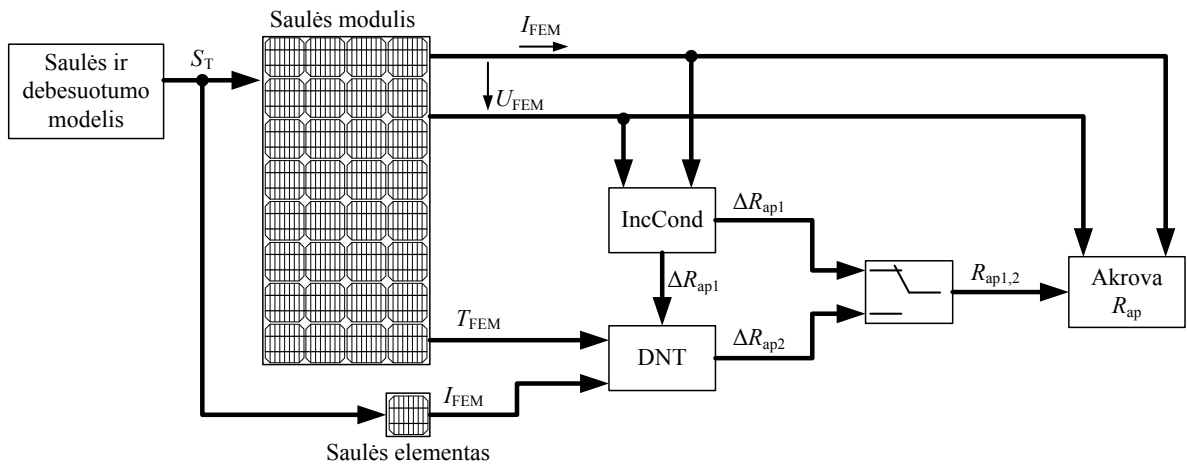
Tyrimo metu buvo analizuojami didžiausios galios taško sekimo algoritmai ir tiriama dirbtinių neuronų tinklo įtaka DGT sekimui.

## Modelio aprašymas

Dirbtinių neuronų tinklo įtakai DGT sekimui ištirti naudojamas ankstesniuose tyrimuose sudarytas matematinis saulės jėgainės modelis (Vasarevičius, Pikutis 2012), kuris yra papildytas dirbtinių neuronų tinklo bloku.

Struktūrinė šio modelio schema pateikta 2 pav. Modelį sudaro saulės ir debesuotumo blokas, kurio generuojamas signalas artimas Lietuvoje krintančiam saulės galios srautui. Saulės galios srauto signalas siunčiamas į saulės modulio ir pavienio saulės elemento blokus. SM blokas imituoja realų saulės modulį, sudarytą iš trisdešimt dviejų saulės elementų. Priklausomai nuo norimų tirti darbo charakteristikų, šis blokas gali būti pakeistas saulės modulių masyvu. Šalia saulės modulio naudojamas pavienis saulės elementas, kuris vykdo piranometro funkciją – matuoja krintančios saulės galios srauto lygį. Lygiagrečiai su saulės elementu prijungus žinomo dydžio varžą, srovės priklausomybė nuo saulės galios srauto yra artima tiesiai. Ši priklausomybė yra taikoma dirbtinių neuronų tinklui mokytui bei jam dirbti toliau.

Saulės modulio generuojama įtampa  $U_{FEM}$  siunčiama į apkrovą. Per ją teka SM srovė  $I_{FEM}$ . Pasirinktas didžiausios galios taško sekimo *IncCond* (Esrām, Chapman 2007) algoritmas arba apmokytas dirbtinių neuronų tinklas (Lee *et al.* 2010) keičia apkrovimo varžos dydį palaikydamas didžiausios galios režimą. Šis DGTS algoritmas pasirinktas dėl galimybės stabiliai dirbti aptiktame didžiausios galios taške. Tik esant stabiliam algoritmo darbui galimas kokybiškas DNT mokymas.



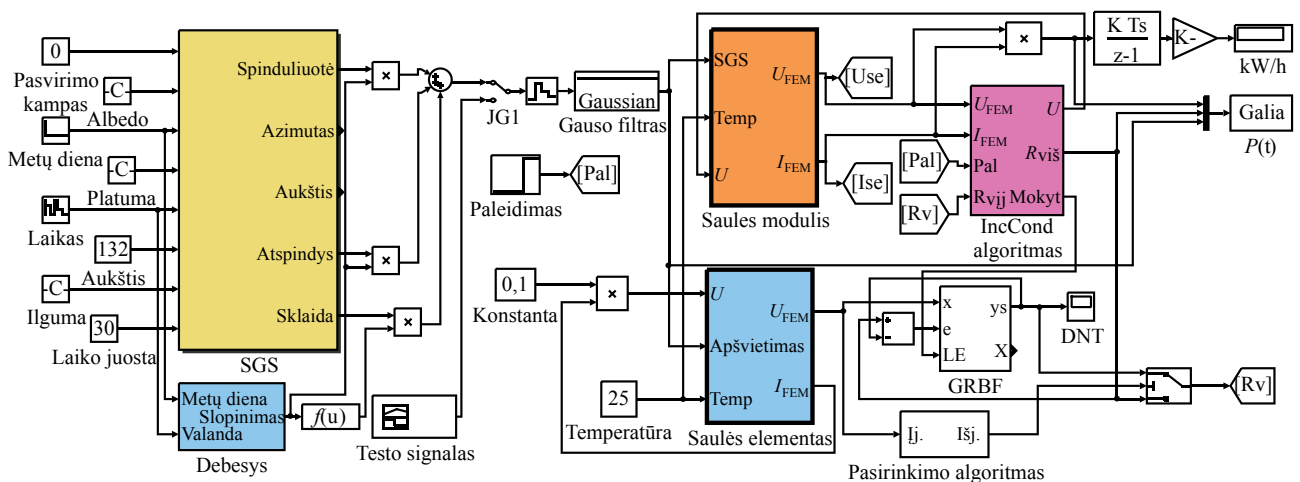
2 pav. Matematinio modelio struktūrinė schema  
 Fig. 2. Structural diagram of a mathematical model

Dirbtinių neuronų tinklo mokymas vyksta tuomet, kai *IncCond* algoritmas pasiekia didžiausią galios tašką. Tuomet į DNT bloką įrašoma algoritmo aptikta apkrovos varžos vertė esant tuo metu išmatuotoms modulių temperatūros bei šalia esančio SE srovės vertėms. Taip dirbtinių neuronų tinklas yra mokomas, o aptikęs artimas apmokytoms aplinkos sąlygas, pats parenka apkrovos varžos pokytį  $\Delta R_{ap2}$ , kuris garantuoja optimalią apkrovą (Hatti *et al.* 2010). Taigi lėtas *IncCond* algoritmas palaipsniui tampa nebenaudojamas, nes jo funkcijas vykdo dirbtinių neuronų tinklas.

### Saulės jėgainės modelis *Matlab/Simulink* terpėje

Pagal saulės jėgainės struktūrinę schemą sudarytas matematinis saulės jėgainės modelis, įgyvendintas *Matlab/Simulink* terpėje, pateiktas 3 pav.

Saulės galios srauto bloke (SGS) sukuriama signalas, imituojantis saulės galios srautą, krintantį į saulės modulį. Saulės galios srauto signalui valdyti naudojami parametrai: pasvirimo kampas, albedo, metų diena, platumas, laikas, aukštis, ilguma, laiko juosta. Šiais parametrais imituojamas SGS skirtingose žemės paviršiaus vietose konkrečiu laiku. Sukurtame modelyje imituojamas šviesiojo paros laiko saulės galios srauto signalas, kurio trukmė – 14 valandų. Modelyje numatyta, kad saulė teka 6:00 val., o leidžiasi – 20:00 val. Kadangi saulės jėgainės valdiklis efektyvus esant sudėtingoms aplinkos sąlygoms, tai modelyje numatytas debesuotumo imitavimo blokas (Debesys). Šio bloko paskirtis chaotiškai slopinti generuojamą SGS signalą ir imituoti debesų slinkimą danguje. SGS ir debesų blokų išėjimų signalų suma siunčiama į Gauso filtrą. Taip gaunamas saulės galios srauto signalas, imituojantis realias aplinkos sąlygas.



3 pav. *Matlab/Simulink* modelis DGT sekimo su dirbtinių neuronų tinklu tyrimams  
 Fig. 3. *Matlab/Simulink* model for observation of MPPT algorithms with artificial neural network

Šis signalas siunčiamas į saulės modulį ir pavienį saulės elementą imituojančius modelio blokus. Tai imituoja į SM paviršių patenkančią saulės galios srautą. Imituojant saulės modulį ir pavienį saulės elementą būtina nurodyti jų paviršiaus temperatūrą. Tyrimo metu laikyta, kad paviršiaus temperatūra nekinta ir lygi 25 °C.

Saulės jėgainės valdiklį modelyje imituoja 3 pav. dešinėje esantis *IncCond* algoritmo įgyvendinimo blokas, skirtas didžiausiam galios taškui sekti jėgainėje ir dirbtinių neuronų tinklui mokytį. DNT mokomas tik tuomet, kai *IncCond* algoritmas yra didžiausiame galios taške arba esant itin mažai nuokrypui nuo didžiausios galios taško. Kai dirbtinių neuronų tinklas yra apmokytas, DGT sekimą vykdo GRBF blokas. Sukurtas ir modelyje įgyvendintas pasirinkimo algoritmo blokas parenka didžiausios galios taškui sekti *IncCond* algoritmą arba DNT. Jis 3 pav. pavadintas Pasirinkimo algoritmu.

### Dirbtinių neuronų tinklo įtaka saulės jėgainės našumui

Saulės jėgainės darbo efektyvumui tirti, esant skirtingiems saulės modulio darbo režimams, buvo generuotas saulės galios signalas. Į šį signalą buvo įterptas imituojantis debesuotumą triukšmas. Taip gautas jėgainei testuoti skirtas signalas yra išsaugotas modelio bloke Testo signalas. Šis signalas per jungiklį JG1 buvo daug kartų siunčiamas į saulės jėgainę.


4 pav. pateiktos saulės jėgainės darbą apibūdinančios charakteristikos, kai didžiausios galios taškas sekamas tik *IncCond* algoritmu. 4 pav., a, pateiktas saulės galios

srautas  $S_T$ , kai imituojant lėtai slenkančius debesis sukuriamos lėtai besikeičiančios aplinkos sąlygos (1 kreivė) ir jėgainės valdiklio parinktos apkrovos  $R_{ap}$  vertės atitinkamu laiko momentu (2 kreivė). 4 pav., b, pateikta charakteristika vaizduoja valdiklio, valdomo *IncCond* algoritmu, gaminamos galios skirtumą nuo teorinės idealios galios atitinkamu laiko momentu. Ši charakteristika vaizduoja jėgainės darbo efektyvumą – prarastos elektros energijos kiekį.

Iš 4 pav. matyti, kad algoritmas aptinka didžiausios galios tašką tik tuomet, kai saulės galios srautas keičiasi lėtai. Kai SGS keičiasi greitai, algoritmas nesugeba per trumpą laiką sumažinti arba padidinti apkrovą. Todėl priartėjimo prie DGT metu yra prarandama dalis elektros energijos. Greitesniam DGT aptikimui siūloma naudoti savaime besimokantį dirbtinių neuronų tinklą.


Saulės jėgainės darbą apibūdinančios charakteristikos, kai didžiausios galios taškas sekamas *IncCond* algoritmu ir dirbtinių neuronų tinklu, pateiktas 5 pav.

5 pav., b, kreivė rodo, kad didžiausi energijos nuostoliai gaunami laikotarpiu iki 13:00 val. Šį laikotarpį didžiąją laiko dalį valdo *IncCond* algoritmas, nes DNT dar nėra užtektinai išmokytas aptikti DGT. Kai dirbtinių neuronų tinklas yra išmokytas, jis tik vienas pradeda valdyti valdiklį. Tai atitinka kreives nuo 13:00 val. Šiuo laikotarpiu apkrovos varža parenkama artima idealiai, o prarasti energijos kiekiai yra artimi nuliui. Be to, laikotarpiu iki 13 val., kai valdiklį valdė *IncCond* algoritmas ir DNT, kuris tuo metu dar buvo mokomas, prarasti energijos kiekiai buvo daug mažesni. Galios skirtumas nesiekė 20 W.




4 pav. Charakteristikos, apibūdinančios saulės jėgainės darbą debesuotą dieną, esant lėtai slenkantiems debesims, kai didžiausios galios taškas sekamas tik *IncCond* algoritmu (a): 1 – saulės galios srauto  $S_T$  kitimo šviesiuoju paros metu kreivė; 2 – *IncCond* algoritmo parinktos apkrovos varžos  $R_{ap}$  verčių kreivė; b – iš saulės modulio paimtos energijos neatitiktis  $\chi_p$  lyginant su atveju, kai apkrovos varža idealiai atitinka didžiausios galios tašką

Fig. 4. Characteristics of solar power plant functioning during the cloudy day with slowly moving clouds, when maximum power point is tracked only using *IncCond* algorithm (a): 1 – alteration of solar irradiance  $S_T$  curve during daylight time; 2 – chosen load resistance  $R_{ap}$  curve using *IncCond* algorithm; b –  $\chi_p$  difference of taken energy from solar module in comparison with case when load resistance corresponds maximum power point ideally



5 pav. Charakteristikos, apibūdinančios saulės jėgainės darbą debesuotą dieną, esant lėtai slenkantiems debesims, kai didžiausios galios taškas sekamas dirbtinių neuronų tinklu ir *IncCond* algoritmu (a): 1 – saulės galios srauto  $S_T$  kitimo šviesiuoju paros metu kreivė; 2 – dirbtinių neuronų tinklo ir *IncCond* algoritmo parinktos apkrovos varžos  $R_{ap}$  verčių kreivė; b – iš saulės modulio paimtos energijos neatitiktis  $\chi_p$  lyginant su atveju, kai apkrovos varža idealiai atitinka didžiausios galios tašką

Fig. 5. Characteristics of solar power plant functioning during the cloudy day with slowly moving clouds, when maximum power point is tracked with artificial neural network and *IncCond* algorithm (a): 1 – alteration of solar irradiance  $S_T$  curve during daylight time; 2 – chosen load resistance  $R_{ap}$  curve using artificial neural network and *IncCond* algorithm; b –  $\chi_p$  difference of taken energy from solar modul in comparison with case when load resistance corresponds maximum power point ideally



6 pav. Charakteristikos, apibūdinančios saulės jėgainės darbą debesuotą dieną, esant greitai slenkantiems debesims, kai didžiausios galios taškas sekamas dirbtinių neuronų tinklu ir *IncCond* algoritmu (a): 1 – saulės galios srauto  $S_T$  kitimo šviesiuoju paros metu kreivė; 2 – dirbtinių neuronų tinklo ir *IncCond* algoritmo parinktos apkrovos varžos  $R_{ap}$  verčių kreivė; b – iš saulės modulio paimtos energijos neatitiktis  $\chi_p$  lyginant su atveju, kai apkrovos varža idealiai atitinka didžiausios galios tašką

Fig. 6. Characteristics of solar power plant functioning during the cloudy day with fast moving clouds, when maximum power point is tracked with artificial neural network and *IncCond* algorithm (a): 1 – alteration of solar irradiance  $S_T$  curve during daylight time; 2 – chosen load resistance  $R_{ap}$  curve using artificial neural network and *IncCond* algorithm; b –  $\chi_p$  difference of taken energy from solar modul in comparison with case when load resistance corresponds maximum power point ideally

6 pav. pateiktos saulės jėgainės darbą debesuotą dieną, esant greitai slenkantiems debesims, apibūdinančios charakteristikos, kai didžiausios galios taškas sekamas *IncCond* algoritmu ir dirbtinių neuronų tinklu. Iš 6 pav. a ir b grafikų matyti, kad dirbtinių neuronų tinklas apmokomas viena valanda ilgiau – valdiklio valdymą jis perima apie 14:00 val. Laikotarpiu iki 14 val., kai valdiklį valdė *IncCond* algoritmas ir DNT, kuris tuo metu dar buvo mokomas, prarasti energijos kiekiai buvo nedideli – prarasti elektros energijos kiekiai tik keletą kartų viršijo 20 W.

## Išvados

1. Skirtingiems saulės elementų tipams būdingos nevienodos charakteristikos ir didžiausios galios taškai. Todėl reikalingas universalus DGT sekimo įrenginys, kuris gebėtų aptikti ir palaikyti DGT net intensyviai keičiantis SE darbo sąlygoms ir jų charakteristikoms.
2. Į saulės modulius jungiamas apėjimo diodas ne tik sumažina prarandamą elektros energijos kiekį esant daliniam šešėliui, bet gali suklaidinti valdiklį ir padidinti prarandamą elektros energijos kiekį.

3. Saulės galios srautui pradėjus kisti greičiau *IncCond* algoritmas nespėja sekti didžiausios galios taško ir dėl to prarandama daug elektros energijos.
4. Savaimė besimokančio dirbtinių neuronų tinklo įdiegimas į saulės jėgainės valdiklį ir jo darbo derinimas su *IncCond* algoritmu leidžia greitai aptikti DGT net greitai besikeičiančiomis aplinkos sąlygomis.

## Literatūra

- Díaz-Dorado, E.; Suárez-García, A.; Carrillo, C.; Cidrás, J. 2010. Influence of the shadows in photovoltaic systems with different configurations of bypass diodes, in *2010 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM)*, 14–16 June, 2010, Pisa, 134–139.  
<http://dx.doi.org/10.1109/SPEEDAM.2010.5542226>
- Esrām, T.; Chapman, P. L. 2007. Comparison of photovoltaic array maximum power point tracking techniques, *IEEE Transactions on Energy Conversion* 2(22): 439–449.
- Hatti, M.; Meharrar, A.; Tioursi, M. 2010. Novel approach of maximum power point tracking for photovoltaic module neural network based, in *EFEEA '10 International Symposium on Environment Friendly Energies in Electrical Applications*, 2–4 November, 2010, Ghardaia, Algeria, 1–6.
- Lee, H. H.; Dzung, P. Q.; Khoa, L. D.; Phuong, L. M.; Vu, N. T. D. 2010. The new maximum power point tracking algorithm using ANN-based solar PV systems, in *IEEE Tencon 2010, IEEE Region Conference*, 21–24 November, 2010, Fukuoka, 2179–2184.  
<http://dx.doi.org/10.1109/TENCON.2010.5686721>
- Vasarevičius, D.; Pikutis, P. 2012. Matematinis saulės energijos srauto modelis didžiausios galios taško saulės elementuose sekimo algoritams tirti, *Mokslas – Lietuvos ateitis* 4(1): 9–12.

## ARTIFICIAL NEURAL NETWORK IN MAXIMUM POWER POINT TRACKING ALGORITHM OF PHOTOVOLTAIC SYSTEMS

**M. Pikutis**

Abstract

Scientists are looking for ways to improve the efficiency of solar cells all the time. The efficiency of solar cells which are available to the general public is up to 20%. Part of the solar energy is unused and a capacity of solar power plant is significantly reduced – if slow controller or controller which cannot stay at maximum power point of solar modules is used. Various algorithms of maximum power point tracking were created, but mostly algorithms are slow or make mistakes. In the literature more and more often artificial neural networks (ANN) in maximum power point tracking process are mentioned, in order to improve performance of the controller. Self-learner artificial neural network and *IncCond* algorithm were used for maximum power point tracking in created solar power plant model. The algorithm for control was created. Solar power plant model is implemented in Matlab/Simulink environment.

**Keywords:** artificial neural network, solar cells, maximum power point tracking.