

Modeliranje difuznega sončnega obseva

Primož Mlakar^{*}, Marija Zlata Božnar^{*}, Boštjan Grašič^{*},
Amauri Pereira de Oliveira^{**}, Jacyra Soares^{**},
Dejan Gradišar^{***}, Juš Kocijan^{***}

Povzetek

Sončna energija predstavlja enega izmed najpomembnejših obnovljivih virov energije. Poznavanje kratkoročnih sprememb polja sončnega obseva je ključnega pomena za proizvodnjo energije. Ker je razmerje med direktnim in difuznim sončnim obsevom pomembno za določitev kvalitete sončne energije, smo razvili model difuznega sončnega obseva na podlagi umetnih nevronske mreže s pomočjo meritev globalnega sončnega obseva in drugih meteoroloških meritev. V prispevku predstavljamo kako se zgradi empirični model difuznega sončnega obseva in kako izbira vhodnih podatkov vpliva na kvaliteto modela.

Ključne besede: difuzni sončni obsev, perceptronska umetna nevronska mreža, meteorološke meritve, vrednotenje modelov

Key words: diffuse solar radiation, artificial perceptron neural network, meteorological measurements, model validation

Uvod

Sončna energija predstavlja enega izmed najpomembnejših obnovljivih virov energije. Pridobivanje lahko poteka neposredno (na primer z uporabo foto-voltaičnih sistemov ali kolektorjev za ogrevanje sanitarne vode) ali na bolj kompleksen način. Na primer kmetijsko pridelovanje rastlin za nadaljnjo izdelavo bioetanola ali drugih kemičnih snovi, ki "vsebujejo" sončno energijo v takšni obliki, da je primerna za prenos in dolgoročno uporabo tako kot uporabljamo bencin.

Proizvodnja bio-goriva ima tudi negativne učinke. Primer tega je poraba najkvalitetnejše kmetijske zemlje za takšno proizvodnjo. Dolgoročno lahko to povzroči probleme pri pridelavi hrane tudi zaradi klimatskih sprememb, poleg tega pa Slovenija ne proizvaja dovolj hrane za svoje lastne potrebe.

Alternativa takšni proizvodnji bio-etanola je proizvodnja alg v morski vodi na posebej oblikovanih območjih s čimer se ohranja najboljša zemlja za pridelavo hrane.

Poznavanje kratkoročnih sprememb polja sončnega sevanja je poleg proizvodnje energije tudi ključnega pomena za kmetijstvo, urbanistično načrtovanje in težave, povezane z onesnaženjem ozračja (Stanhill & Cohen, 2001). Za uveljavitev strategij, povezanih z energetske načrtovanjem, je pomembno, da zberemo vse razpoložljive znanstvene informacije o sončnem sevanju ter razvijemo in preizkusimo modele za napovedovanje sončne energije v različnih časovnih skalah, ki jih je mogoče uporabiti za večja območja (Jebaraj & Iniyamb, 2006).

Ne glede na kakšno izrabo sončne energije se odločimo pa nas zanima koliko energije je na razpolago in kakšne kvalitete je (Moheimani, 2005). Zato se izvajajo meritve globalnega sončnega obseva, difuznega in včasih tudi direktnega. Meritve globalnega

^{*} MEIS storitve za okolje, d.o.o., Mali Vrh pri Šmarju 78, SI-1293, Šmarje-Sap, Slovenija

^{**} Group of Micrometeorology, Department of Atmospheric Sciences, University of São Paulo, São Paulo, Brazil

^{***} Institut Jožef Stefan, Jamova 39, SI-1000, Ljubljana

sončnega obseva so relativno enostavne, zato se pogosto izvajajo na avtomatskih meteoroloških postajah. Meritve difuznega obseva in še posebej direktnega sončnega obseva so redke zaradi zahtevnosti meritev.

Ker je razmerje med direktnim in difuznim sončnim obsevom pomembno za določitev kvalitete sončne energije, smo razvili model difuznega sončnega obseva na podlagi umetnih nevronske mreže s pomočjo meritev globalnega sončnega obseva in drugih meteoroloških meritev.

Modeliranje sončnega obseva

Polje sončnega sevanja na površju sestavljajo direktni svetlobni snop in razpršene komponente, ki jih je mogoče neposredno oceniti z meritvami (Oliveira et al., 2002a), posredno z metodami modeliranja (Emde & Mayer 2007) ali s kombinacijo obojega na satelitskem prikazu (Pereira et al., 1996).

Metode modeliranja je mogoče opredeliti kot fizikalne ali empirične. Fizikalno modeliranje vključuje numerično rešitev enačbe prenosa sevanja (Ricchiazzi et al., 1998), empirično modeliranje pa ti. regresijske modele (Jacovides et al., 2007) ali postopke z metodami umetnih nevronske mreže (Soares et al., 2004) na predhodno izbranem nizu podatkov.

Včasih razlika med fizikalnim in empiričnim modeliranjem ni povsem jasno opredeljena. Janjai et al. (2009) so na primer razvili model za napovedovanje urnih vrednosti globalnega sončnega obseva Tajske, pri katerem so upoštevali vplive oblakov, aerosolov, ozona in vlažnosti, pri čemer so kot ocene uporabili satelitske slike vstopnega sončnega sevanja na vrhu atmosfere. Ta model je mogoče opredeliti kot fizikalni, saj temelji na enačbi prenosa sevanja, vendar hkrati z veliko mero empiričnih prikazov absorpcije in razpršitve upošteva vplive oblakov in aerosolov ter druge vplive.

Za nas je opredelitev empiričnih modelov znatno težja naloga. S statističnega vidika je mogoče empirične modele opredeliti kot parametrične in neparametrične. Parametrični modeli vključujejo posplošene linearne modele, kot je logistična regresija (Sansigolo, 1997), linearne (Jiang, 2009) in nelinearne regresijske modele, kot so polinomske, odsekovne in sigmoidne funkcije, ter Fourierjeve in podobne transformacije (Li et al., 2010) in avtoregresivne modele, kot sta metoda avtoregresivnega integriranega drsečega povprečja ARIMA (Jain & Lungu, 2002) in proces avtoregresivnih drsečih povprečij ARMA (Zaharim et al., 2009). Neparametrična modela sta umetna nevronska mreža (Senkal & Kuleli, 2009) in mehka logika (Sen, 1998).

Kratek pregled razpoložljive literature kaže več neskladij in napačnih predstav o empiričnih modelih. Bakirci (2009) je na primer izvedel obsežno raziskavo empiričnih modelov, s katero je želel oceniti mesečne povprečne dnevne vrednosti globalnega sončnega obseva na osnovi Angstromove formule. Navedel je šestdeset formul, ki jih je razvrstil v štiri skupine: linearne, polinomske, trigonometrične in druge. Statistično gledano so vsi ti modeli opredeljeni kot parametrični empirični modeli ne glede na uporabljeni izraz za povezavo globalnega sončnega obseva s spremenljivkami, kot so relativno število sončnih ur (razmerje med številom sončnih ur z največjim številom sončnih ur), zemljepisna širina, zemljepisna dolžina, nadmorska višina, deklinacija Sonca, temperatura zraka okolice, relativna vlažnost in količina padavin.

Naslednji primer težav, ki se pojavljajo pri empiričnih modelih, sta navedla Wong in Chow (2001). Po njunem mnenju je mogoče empirični model opredeliti kot parametrični in dekompozicijski. Dekompozicijski modeli so razred empiričnih modelov, pri katerih je glavni vhodni podatek globalni sončni obsev, na primer sklop regresijskih modelov za ultravijolične, fotosintezno aktivne in skoraj infrardeče komponente sončnega sevanja na

površju, ki so ga na osnovi globalnega sončnega sevanja za podeželsko območje Botucatu v Braziliji pripravili Escobedo in drugi (2009).

Merjenje polja sončnega sevanja in situ je najnatančnejši način ocenjevanja globalnega, direktnega in razpršenega sončnega sevanja na površju. Tovrstna dognanja pa je treba z vidikov umerjanja in prostorske »reprezentativnosti« obravnavati z visoko mero previdnosti, zlasti ker večina uporabljenih senzorjev ne upošteva napak, povezanih z vplivi temperature, naklona in prezračevanja (Gueymard & Myers, 2009).

Tehnologija zaznavanja na daljavo ne zagotavlja tako natančnih in zanesljivih podatkov kot meritve in situ, vendar je najučinkovitejša v smislu prostorske reprezentativnosti sončnega obseva (Gupta et al., 1999). Druga težava, povezana s sateliti, so visoki stroški.

Čeprav so rezultati fizikalnih modelov učinkovitejši od empiričnih, je redno ocenjevanje polja sončnega obseva z enačbo prenosa sevanja dokaj težavno. Fizikalni modeli se izvajajo numerično z bolj ali manj poenostavljeno vlogo oblakov, vlažnosti, drugih atmosferskih plinov, prisotnih v manjših deležih, ter aerosolov, kar meče dvom na njihovo sposobnost odsevanja dejanskega stanja.

Difuzni sončni obsev predstavlja pomemben delež celotnega sevanja na površju ter je odvisno od odbojnosti površine, topografije, ki določa delež vidnega neba (Ruiz–Arias et al., 2010), in sestave ozračja, katerega vplivni delež predstavljajo oblaki, trdni delci in vodni hlapi.

Statistično modeliranje kratkotrajnih sprememb difuznega sončnega obseva zahteva uporabo posebnih metod, ki upoštevajo nelinearne zakonitosti, prisotne v kratkem časovnem obdobju. Na splošno so regresijski modeli učinkoviti za mesečne in dnevne vrednosti, vendar z njimi ni mogoče modelirati vpliva oblakov na razpršeno sončno obsevanje po urah, ker je odvisnost zelo nelinearna (Oliveira et al., 2002b).

Naslednja pomembna težava glede empiričnega modeliranja na splošno in zlasti empiričnega modeliranja sončnega obseva je usklajevanje načela preprostosti s potrebo po čim širši uporabnosti. Preprosti empirični modeli so najpogosteje omejeni na določeno regijo in letni čas.

Jacovides et al. (2006) menijo, da je model, ki so ga predlagali Oliveira et al. (2002b) ter Soares et al. (2004), učinkovitejši od regresijskih modelov, vendar nobeden izrecno ne uporablja informacij o vrstah oblakov, ki so eden najpogostejših in najpomembnejših pojavov v ozračju ter pomemben dejavnik podnebne sistema in procesov podnebnih sprememb (Stephens, 2005).

Naslednji dejavnik, ki otežuje ocenjevanje globalnega sončnega obseva na mestnih območjih pa tudi drugje, je onesnaženost zraka. Onesnažen zrak vpliva na razpršeno sončno obsevanje neposredno z razpršitvijo na aerosolih (Pereira et al., 2000) in posredno z zvečanjem števila vodnih kapljic v oblakih v onesnaženem zraku (Rosenfeld & Woodley, 2001).

Soares et al. (2004) smo za premostitev teh težav uporabili metodo umetnih nevronske mreže, s katero smo ocenili difuzni sončni obsev po urah. Metode z uporabo umetnih nevronske mreže implicitno upoštevajo oblačnost in druge parametre. Umetne nevronske mreže so se namreč sposobne naučiti te vzorce. Edina težava pri tej metodi je ta, da umetne nevronske mreže težko uporabljajo osebe, ki niso razvile algoritma. Ta slabost je značilna za večino neparometričnih modelov.

Metode modeliranja povprečnega polurnega difuznega sončnega obseva na Letališču Portorož

Na Letališču Portorož ob sečoveljskih solinah je avtomatska meteorološka postaja (AMP) ARSO-a, katera je opremljena s standardnimi merilniki, ki jih potrebuje manjše

letališče. Poleg merilnika za globalni sončni obsev ima postaja tudi merilnik za difuzni sončni obsev, ki potrebuje premikanje senčila dvakrat na teden ob enakonočju, ko so spremembe največje. Ob sončnem obratu pa je ta interval bistveno daljši. Ker je na letališču vsak dan dežurni meteorolog, je postaja zelo dobro vzdrževana.

Postaja vzorčuje podatke o sončnem obsevu na nekaj sekund in jih vsake polure statistično obdela in shrani.

Od ARSO-a smo dobili vse polurne podatke meritev AMP Letališče Portorož od 1.1.2012 do 30.6.2014. Ta merilna baza je bila osnova za razvoj modelov za difuzni sončni obsev in za njihovo vrednotenje. Merilnih podatkov, ki smo jih uporabili za razvoj, nismo uporabili za vrednotenje modelov.

Za modeliranje smo uporabili metodo umetnih nevronske mreže (UNM). Izbrali smo Perceptronsko UNM s katero imamo največ izkušenj. UNM nismo sami razvijali, uporabili smo UNM z dobrimi referencami (NeuroShell,2014).

V avtomatiki in pri razpoznavanju vzorcev je postopek modeliranja procesov z UNM zelo uveljavljen. Postopek je sestavljen iz:

1. izbire značilk (v avtomatiki se imenujejo regresorji),
2. izbire vzorcev za učno in testno množico ter množico za vrednotenje modela,
3. učenje UNM,
4. vrednotenje rezultatov.

Če nismo zadovoljni z rezultati, običajno ponovimo postopek z drugimi ali dodanimi značilkami.

Ker so ti izrazi tuji raziskovalcem iz drugi ved, bomo izraze razložili na primeru preprostega modela za povprečni polurni difuzni sončni obsev. S tem smo izbrali izhod iz modela, ki se imenuje izhodna značilka. Za vhode v model izberemo povprečne polurne merilne podatke globalnega sončnega obseva, temperature zraka na višini 2 m, relativne vlažnosti zraka, hitrosti vetra in trenutne ure v dnevu v istem času kot je izhodna značilka. Lahko bi izbrali merilne podatke iz prejšnjega časovnega intervala ali več časovnih intervalov nazaj. To so vhodne značilke. Vzorec pa je vektor vrednosti vhodnih in izhodnih značilk v določenem času. Značilka ni nujno merjen podatek. Uro v dnevu smo dodali, ker predvidevamo, da je močna povezava med časom v dnevu in difuznim sončnim obsevom. Poudariti je potrebno, da, če želimo »napovedati« difuzni sončni obsev, moramo imeti merilne podatke difuznega sončnega obseva za razvoj – izgradnjo modela.

Pred učenjem UNM moramo nastaviti ustrezne datoteke, da UNM lahko prebere podatkovne datoteke z učnimi in testnimi vzorci. V procesu učenja UNM za učenje uporablja učne vzorce. Testne vzorce pa uporablja za optimizacijo učenja, ker je najboljši model tisti, ki ima najmanjšo napako na testnih vzorcih.

Kvaliteto dobljenega modela pa lahko nato določimo z množico vzorcev za vrednotenje, ki niso bili uporabljeni med procesom učenja. Za vrednotenje običajno uporabljamo različne cenilke na primer: korelacijo, vsoto kvadratov napake, odklon (bias), ...

Rezultati

Za model difuznega obseva na postaji Portorož smo pripravili več modelov katerih cilj je bil empirično določiti čim bolj optimalen model glede na razpoložljivost meritev.

V tem poglavju bomo predstavili dva modela, od katerih je eden zelo uspešen (»Nadgrajeni«), drugi pa nekoliko manj (»Osnovni«). Tako bomo lahko predstavili razlike, ki do tega privedejo.

Za izgradnjo modela smo uporabili podatke izmerjene v letu 2012. Podatke iz leta 2013 in prve polovice leta 2014 pa smo uporabili zgolj za neodvisno preizkušanje – vrednotenje

modela. Vrednotenje je tako potekalo na obširnem podatkovnem setu, ki v procesu izgradnje modela ni bil udeležen. Zadosti velika množica podatkov za vrednotenje (okvirno za polovico večja od podatkov za izgradnjo modela) pa je poleg časovne zaporednosti garancija za solidno neodvisno oceno kvalitete zgrajenih modelov.

Podatke iz leta 2012 smo nadalje razdelili na manjšo množico za optimizacijo (20 % naključno izbranih vzorcev) in preostalo množico za učenje. Proces učenja je bil vedno izveden z algoritmom povratnega širjenja vpliva napake (»backpropagation«), ki je eden od osnovnih možnih. Umetna nevronska mreža je imela topologijo klasične perceptronske nevronske mreže, z dvema skritima nivojema. Vsak od skritih nivojev je imel po 46 nevronov, vsak od teh nevronov pa nelinearno sigmoidno prenosno funkcijo. Končna naučena nevronska mreža za model je bila tista, ki je pokazala najmanjšo povprečno kvadratno napako napovedi difuznega obseva na optimizacijskih vzorcih. Ta model smo potem preizkusili na množici vzorcev za vrednotenje.

Vse značilke smo normirali glede na pričakovani razpon merilnih ali izračunanih vrednosti. Za vse meritve smo uporabljali polurne povprečne vrednosti.

Pri prvem modelu imenovanem »Osnovni« smo uporabili naslednje polurne povprečne značilke: temperaturo zraka, relativno vlažnost zraka, globalno sončno obsevanje, zračni tlak, hitrost vetra, padavine ter zaporedno številko dneva v letu in uro v dnevu. Model je dal solidno dobre rezultate na množici za vrednotenje. Vrednosti cenilk so predstavljene v preglednici 1. Podrobna definicija cenilk je na voljo v delovnem priročniku orodja Delta Tool, ki je izdelan v okviru FAIRMODE foruma za modeliranje onesnaževanja ozračja v Evropi (Thunis et al., 2011). Najbolj smo se za kvaliteto modela orientirali po cenilki R (Pearsonov koeficient korelacije), ki je znašala 0.902.

Preglednica 1 - Vrednosti cenilk za »Osnovni« model

Cenilka		Vrednost
Pearsonov koeficient korelacije (Pearson correlation coefficient)	R	0.902
Celotna napaka (root mean square error)	RMSE [W/m²]	38.0
Srednji delež odklona (Mean fractional bias)	MFB	-0.0384
Faktor 2 (Factor of modelled values within a factor of two of observation)	FAC2	0.917

FAC2 je razmerje med številom modeliranih vrednosti, ki so na intervalu med 0.5 in 2.0 merjene vrednosti, in številom vseh modeliranih vrednosti.

Zatem pa smo model izboljšali tako, da smo navedenim vhodnim značilkam dodali še dve značilki in sicer horizontalno instrumentalno vidljivost (RVR) in bazo oblakov. Obe značilki sta klasični avtomatski meritvi, ki se ju izvaja na vseh solidno opremljenih letališčih. RVR je vidljivost v vodoravni smeri (RVR,2014), baza oblakov pa je višina na kateri se nahaja prvi sloj oblakov. Obe meritvi sta avtomatizirani do te mere, da zahtevata le občasno vzdrževanje, podobno kot ostali meteorološki senzorji. Pomembno je, da ti dve

meritvi ne zahtevata pogostega nastavljanja ali kontroliranja, kar je sicer običajno zahtevano za merilnike difuznega in direktnega sončnega obseva. Dodatni izbrani značilki sta izjemnega pomena zato, ker nam vodoravna vidljivost precej pove o prisotnosti megle, ki razprši sončno svetlobo. Prisotnost oblakov pa tudi ključno vpliva na razmerje direktno / difuzno sončno obsevanje. Avtomatski merilnik pa nam ne omogoča identifikacije vrste oblakov, kar bi bilo dodatno zelo uporabno.

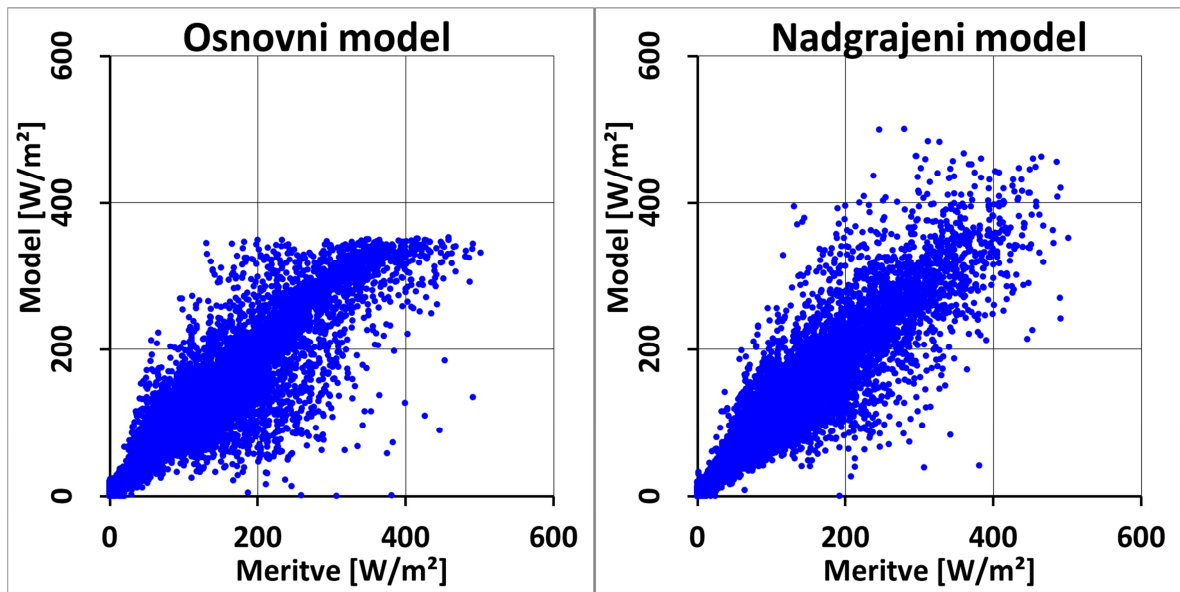
Novi model imenovan »Nadgrajeni« z dodatnima značilkama je izboljšal ključno cenilko R na vrednost 0.924. V preglednici 2 so prikazane še vrednosti ostalih cenilk v primerjavi z »Osnovnim« modelom.

Na sliki 1 sta predstavljena grafa raztrosa merjenih in napovedanih vrednosti difuznega sončnega obseva za oba modela. Graf raztrosa »Nadgrajenega« modela kaže v glavnem zelo solidno obnašanje modela, nekaj pa je merilnih ali napovedanih vrednosti, ki se zelo približajo osem, kar kaže, da je še vedno nekaj merilnih vzorcev katerih obnašanja ne moremo opisati z informacijo, ki jo nosijo merilne vrednosti izbranih značilk. To je zaenkrat odprto polje za nadaljnje delo.

Sledijo še trije izseki – grafi časovno zaporednih merjenih in napovedanih vrednosti difuznega sončnega obseva na sliki 2 za lažjo predstavbo kako dober ali pa kako slab je lahko model. Uporabljene so vrednosti drugega opisanega modela »Nadgrajeni« z večimi značilkami in množico vzorcev za vrednotenje.

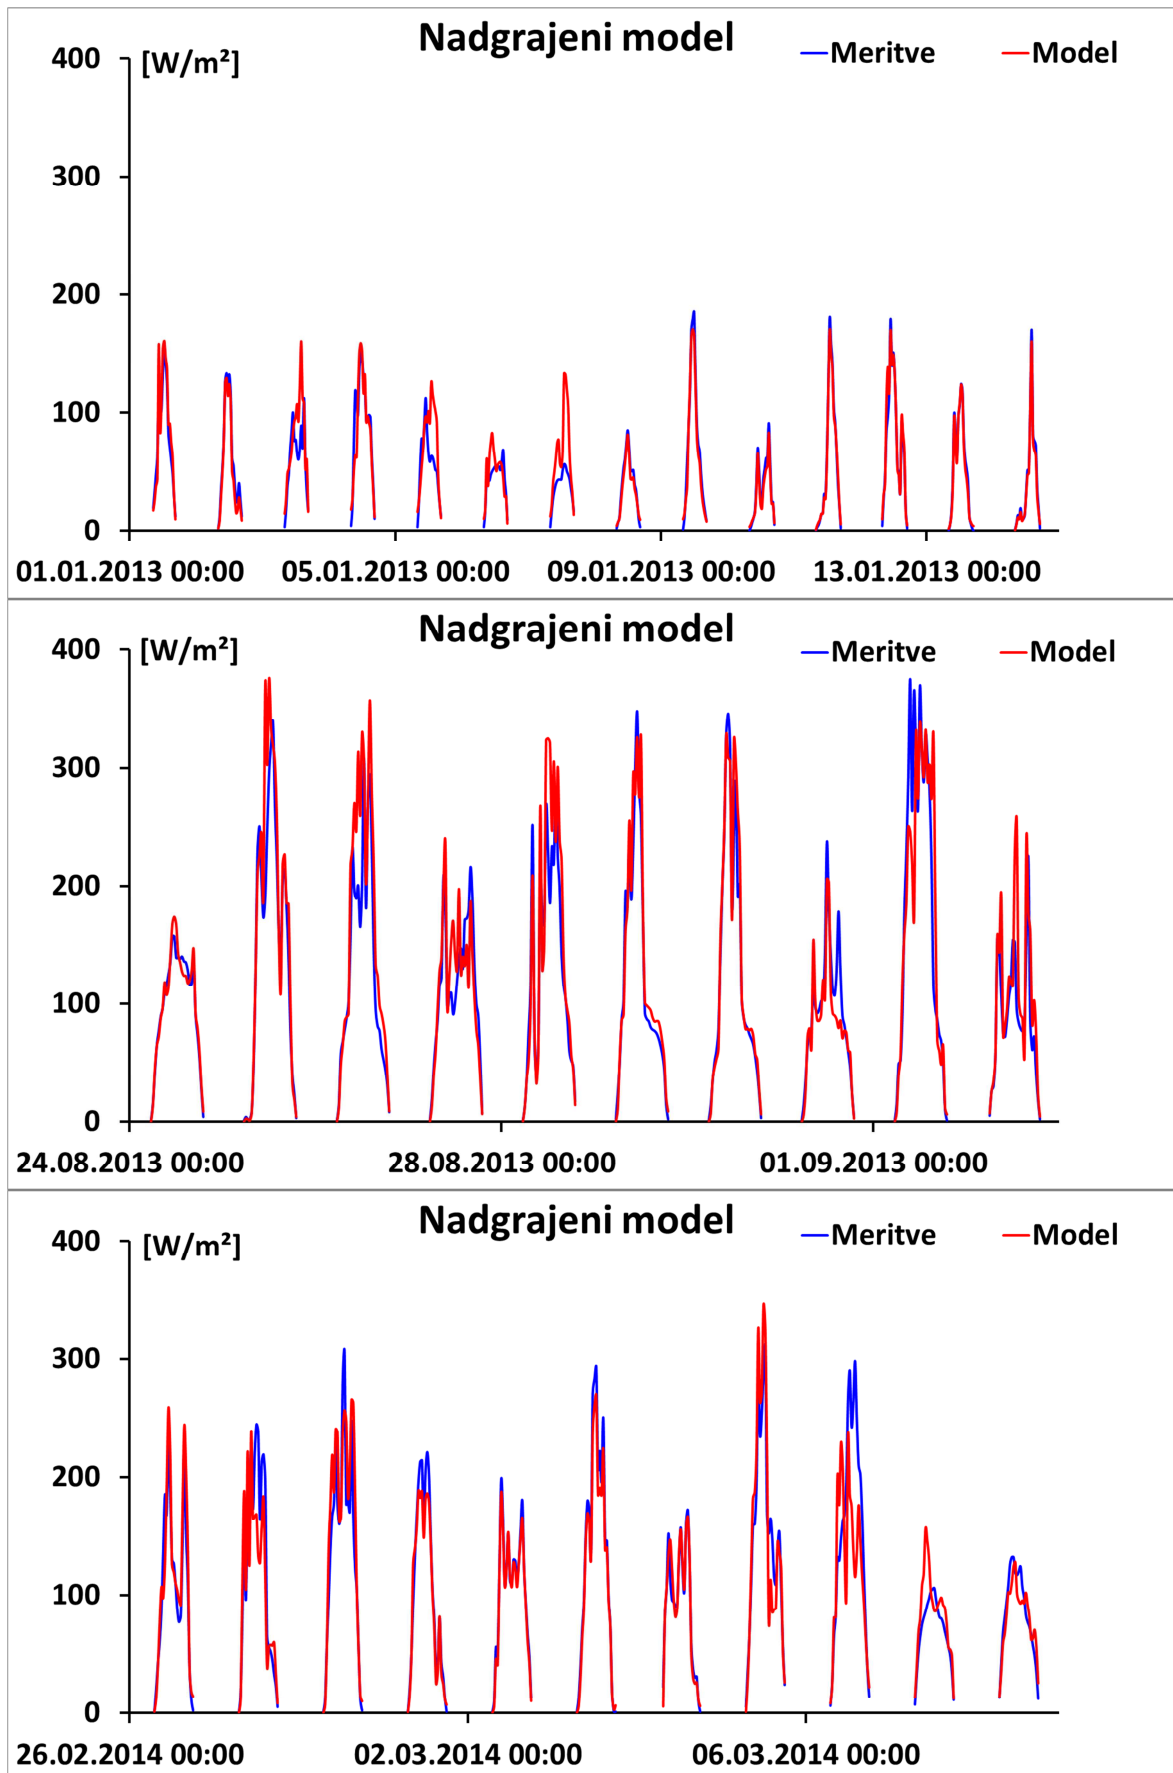
Preglednica 2 - Primerjava vrednosti cenilk med modeloma

Cenilka	Osnovni	Nadgrajeni
Pearsonov koeficient korelacije (Pearson correlation coefficient) R	0.902	0.924
Celotna napaka (root mean square error) RMSE [W/m²]	38.0	33.9
Srednji delež odklona (Mean fractional bias) MFB	-0.0384	0.0024
Faktor 2 (Factor of modelled values within a factor of two of observation) FAC2	0.917	0.944



Slika 1 – Grafa raztrosa merjenih in napovedanih vrednosti difuznega sončnega obseva obeh modelov

Že na prvi pogled so rezultati za »Nadgrajeni« model boljši kot pri »Osnovnem«. Pri »Osnovnem« modelu je očitna omejenost pri približno 350 W/m^2 . Slabost pripisujemo premajhni informacijski vsebnosti učnih vzorcev opisanih z navedenimi značilkami.



Slika 2 – Grafi časovno zaporednih merjenih in napovedanih vrednosti difuznega sončnega obseva za »Nadgrajeni« model

Razprava

Modeli na osnovi umetnih nevronske mreže so ena od pomembnih vrst modelov, ki so še posebej uporabni v primerih, ko imamo na voljo daljše nize zgodovinskih merjenih podatkov na izbrani lokaciji za katero želimo z modelom ponazoriti merjen fizikalni parameter.

Pri izbiri vrste umetne nevronske mreže smo upoštevali, da je matematično dokazano, da je ustrezno konfigurirana perceptronska nevronska mreža z dvema skritima nivojema z nelinearno prenosno funkcijo univerzalni aproksimator. Kar pomeni, da z njo lahko dovolj dobro ponazorimo (aproksimiramo) poljubno nelinearno funkcijo večih vhodnih spremenljivk, pogoj je le, da ta nelinearna funkcija nima singularnosti (Hornik, 1991; Kurkova, 1992). Ker smo aproksimator izbrali za ponazoritev meteoroloških meritev, katerih časovni nizi podatkov nimajo singularnosti, je to vsekakor ustrezna uporaba tega univerzalnega aproksimatorja.

Zgrajena modela kažeta na to, da že z osnovnimi meteorološkimi meritvami lahko postavimo soliden model difuznega sončnega obseva. Če pa model nadgradimo še z meritvami letališke meteorologije, pa ga še izboljšamo. Slabost takega modelskega pristopa je edino v tem, da zahteva vnaprej izvedeno obdobje, ko merimo tudi modelirani parameter – difuzno sončno obsevanje. Ko pa je model zgrajen, lahko meritev umaknemo (jo na primer prestavimo na drugo lokacijo kjer si tudi želimo zgraditi model).

Solidno dobra informacija o izmerjenih vrednostih in vsakokratnem razmerju med difuznim in direktnim sončnim obsevanjem je ključna vhodna informacija za inženirsko načrtovanje sončnih elektrarn. Poleg seveda vseh ostalih tudi od geografske lokacije odvisnih vrednosti (Rakovec et al., 2011).

Sklep

Predstavili smo dva relativno enostavna in kljub temu solidno uspešna modela difuznega sončnega obsev zgrajena na osnovi perceptronske umetne nevronske mreže.

Perceptronska umetna nevronska mreža je univerzalni aproksimator in je kot taka široko uporabna za različne ponazoritve meteoroloških parametrov (Mlakar & Božnar, 2011).

Zahvala

Raziskavo je delno financirala ARRS – Javna agencija za raziskovalno dejavnost Republike Slovenije, projekta št. L2-5475 in L1-4154.

Literatura

- Bakirci, K. (2009). Models of solar radiation with hours of bright sunshine: A review. *Renewable and Sustainable Energy Reviews*, 13, 2580–2588.
- Emde, C., Mayer, B. (2007). Simulation of solar radiation during a total eclipse: a challenge for radiative transfer. *Atmospheric Chemistry and Physics*, 7, 2259–2270.
- Escobedo, J. F., Gomes, E. N., Oliveira, A. P., Soares, J. (2009). Modeling hourly and daily fractions of UV, PAR and NIR to global solar radiation under various sky conditions at Botucatu, Brazil. *Applied Energy*, 86, 299–309.

- Gueymard, C.A., Myers, D. R. (2009). Evaluation of conventional and high-performance routine solar radiation measurements for improved solar resource, climatological trends, and radiative modeling. *Solar Energy*, 83,171–85.
- Gupta, S. K., Ritchey, N. A., Wilber, A. C., Whitlock, C. H., Gibson, G. G., Stackhouse, Jr. P.W. (1999). A climatology of surface radiation budget derived from satellite data. *Journal of Climate*, 12, 2692–710.
- Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks* 4, 251-257
- Jacovides, C. P., Tymvios, F. S., Assimakopoulos, V. D., Kaltsounides, N.A. (2007). The dependence of global and diffuse PAR radiation components on sky conditions at Athens, Greece. *Agricultural and Forest Meteorology*, 143, 277–87.
- Jacovides, C. P., Tymvios, F. S., Assimakopoulos, V. D., Kaltsounides, N.A. (2006). Comparative study of various correlations in estimating hourly diffuse fraction of global solar radiation. *Renewable Energy*, 31, 2492–504.
- Jain, P.K., Lungu, E.M. (2002). Stochastic models for sunshine duration and solar irradiation. *Renewable Energy*, 27, 197–209.
- Janjai, S., Pankaew, P., Laksanaboonsong, J. (2009). A model for calculating hourly global solar radiation from satellite data in the tropics, *Applied Energy*, 86(9), 1450-1457 (DOI: 10.1016/j.apenergy.2009.02.005).
- Jebaraj, S., Iniyamb, S. A (2006). Review of energy models. *Renewable and Sustainable Energy Review*,10, 281–311.
- Jiang, Y. (2009). Estimation of monthly mean daily diffuse radiation in China. *Applied Energy*, 86(9), 1458-1464 (DOI: 10.1016/j.apenergy.2009.01.002).
- Kurkova, V. (1992). Kolmogorov's Theorem and Multilayer Neural Networks, *Neural Networks*, 5, 501-506
- Li, H., Ma, W., Lian, Y., Wang X. (2010). Estimating daily global solar radiation by day of year in China. *Applied Energy*, 87, 3011-3017(DOI: 10.1016/j.apenergy.2010.03.028).
- Mlakar, P., Božnar, M. Z. (2011). Artificial Neural Networks - a Useful Tool in Air Pollution and Meteorological Modelling, *Advanced Air Pollution*, Dr. Farhad Nejadkoorki (Ed.), ISBN: 978-953-307-511-2, InTech, DOI: 10.5772/20824. Available from: <http://www.intechopen.com/books/advanced-air-pollution/artificial-neural-networks-a-useful-tool-in-air-pollution-and-meteorological-modelling>
- Moheimani, N. R. (2005). The culture of coccolithophorid algae for carbon dioxide bioremediation. PhD thesis. Murdoch University. Australia, 252 pp.
- NeuroShell 2, Ward Systems Group, Inc. (2014). <http://www.wardsystems.com/neuroshell2.asp> (20.11.2014).
- Oliveira, A. P., Escobedo, J. F., Machado, A. J., Soares, J. (2002a). Diurnal evolution of solar radiation at the surface in the City of São Paulo: seasonal variation and modeling. *Theoretical and Applied Climatology*, 71(3-4), 231-249.
- Oliveira, A. P., Escobedo, J. F., Machado, A. J., Soares, J. (2002b). Correlation models of diffuse solar radiation applied to the City of São Paulo (Brazil). *Applied Energy*, 71(1), 59-73.
- Pereira, E. B., Abreu, S. L., Stuhlmann, R., Rieland, M., Colle, S. (1996). Survey of the incident solar radiation in Brazil by use of Meteosat satellite data. *Solar Energy*, 57(2), 125-132.
- Pereira, E. B., Martins, F. R., Abreu, S. L., Couto, P., Stuhlmann, R., Colle, S. (2000). Effects of burning of biomass on satellite estimations of solar irradiation in Brazil. *Solar Energy*, 68(1), 91–107.
- Rakovec, J., Zakšek, K., Brecl, K., Kastelec, D., Topic, M. (2011). Orientation and Tilt Dependence of a Fixed PV Array Energy Yield Based on Measurements of Solar Energy and Ground Albedo – a Case Study of Slovenia, *Energy Management Systems*, Dr Giridhar Kini (Ed.), ISBN: 978-953-307-579-2, InTech, DOI: 10.5772/18386. Available from: <http://www.intechopen.com/books/energy-management-systems/orientation-and-tilt-dependence-of-a-fixed-pv-array-energy-yield-based-on-measurements-of-solar-ener>
- Ricchiazzi, P., Yang, S., Gautier, C., Sowle, D. (1998). SBDART: A Research and Teaching Software Tool for Plane-Parallel Radiative Transfer in the Earth's Atmosphere. *Bulletin of the American Meteorological Society*, 79, 2101-2114.

- Rosenfeld, D., Woodley, W. (2001). Pollution and clouds. *Physics World*, February, 33–7.
- Ruiz-Arias, J.A., Cebecauer, T., Tovar-Pescador, J., Suri M. (2010). Spatial disaggregation of satellite-derived irradiance using a high-resolution digital elevation model. *Solar Energy* (doi:10.1016/j.solener.2010.06.002).
- RVR, http://en.wikipedia.org/wiki/Runway_visual_range, (20.12.2014).
- Sansigolo, C. A. (1997). Non-Stationary Markov Chains for Modelling Daily Sunshine at São Paulo, Brazil. *Theoretical and Applied Climatololgy*, 56, 225-230.
- Sen, Z. (1998). Fuzzy algorithm for estimation of solar irradiation from sunshine duration. *Solar Energy*, 63(1), 39–49.
- Senkal, O., Kuleli, T. (2009). Estimation of solar radiation over Turkey using artificial neural network and satellite data. *Applied Energy*, 86(7-8), 1222-1228 (DOI: 10.1016/j.apenergy.2008.06.003).
- Soares, J., Oliveira, A. P., Božnar, M. Z., Mlakar, P., Escobedo, J. F., Machado, A. J. (2004). Modeling hourly diffuse solar radiation in the city of São Paulo using neural network technique. *Applied Energy*, 79, 201–14.
- Stanhill, G., Cohen, S. (2001). Global dimming: A review of the evidence for a widespread and significant reduction in global radiation with discussion of its probable causes and possible agricultural consequences. *Agricultural and Forest Meteorology*, 107, 255–78.
- Stephens, G. L. (2005). Cloud Feedbacks in the Climate System: A Critical Review. *Journal of Climate*, 18, 237-273.
- Thunis, P., Georgieva, E., Pederzoli, A. (2011). The DELTA tool and Benchmarking Report template, Version 1, FAIRMODE, Forum for air quality modelling, Joint Research Centre, Ispra, European Comission, <http://aqm.jrc.ec.europa.eu/DELTA/> (12.11.2014).
- Wong, L.T., Chow, W.K. (2001). Solar radiation model. *Applied Energy*, 69, 191–224.
- Zaharim, A., Razali, A. M., Gim, T. P., Sopian, K. (2009). Time series analysis of solar radiation data in the tropics, *European Journal of Scientific Research*, vol. 25, no. 4, 672–678