

UNIVERZA V NOVI GORICI
POSLOVNO-TEHNIŠKA FAKULTETA

**MODELIRANJE NAPOVEDOVANJA PROIZVODNJE
ELEKTRIČNE ENERGIJE IZ SONČNIH ELEKTRARN**

DIPLOMSKO DELO

Karolina Koren

Mentor: doc. dr. Irina Elena Cristea

Nova Gorica, 2014

ZAHVALA

Zahvaljujem se družbi E 3, energetika, ekologija, ekonomija, d.o.o., ki mi je omogočila opravljanje praktičnega usposabljanja. Za pridobitev potrebnih meritvenih podatkov se zahvaljujem tudi matični družbi Elektro Primorska, d.d. V času pisanja diplomskega dela sem pridobila mnogo novih in uporabnih znanj, ki jih bom lahko vpeljala v nadaljnje delo in jih nadgrajevala. Da sem vse to dosegla, je zaslužen kolektiv družbe E 3, energetika, ekologija, ekonomija, d.o.o., kjer moram izpostaviti mentorja praktičnega usposabljanja Miloša Protića, univ. dipl. inž. el., ki je podal predlog za pisanje diplomskega dela in mi s svojim širokim znanjem pomagal pri praktičnem delu pričujočega dela. Za vso pomoč, potrpežljivost, čas in znanja se vsakemu posebej iskreno zahvaljujem. Prav tako je znanje z menoj delila mentorica na fakulteti, doc. dr. Irina Elena Cristea, ki se ji zahvaljujem za posluh ob izbiri tematike diplomskega dela. Ne nazadnje so bili na moji dosedanji poti vseskozi prisotni starši, ki so bili moji prvi učitelji, zato se iskreno zahvaljujem tudi vam za vso pomoč, ki sem jo bila deležna v času študija, in vero v moj uspeh.

NASLOV

Modeliranje napovedovanja proizvodnje električne energije iz sončnih elektrarn

IZVLEČEK

Za cilj diplomskega dela smo si zadali iskanje odnosa med proizvodnjo električne energije in vremenskimi dejavniki. Iz dobljenih rezultatov, izpeljav in ugotovitev pa smo zasnovali modele za načrtovanje proizvodnje v sončnih elektrarnah.

Analizirali smo obsežne sledove zgodovinskih podatkov iz vremenskih postaj, kot tudi ustrezne vremenske napovedi Agencije Republike Slovenije za okolje, da smo med seboj povezali vremenske meritve. Naša analiza količinsko ovrednoti kako vsaka vremenska spremenljivka vpliva na ostale in na globalno sevanje, ki je najvplivnejša vremenska spremenljivka na proizvodnjo električne energije iz sončnih elektrarn. Ugotovili smo, da hitrost vetra nima občutne povezave s proizvodnjo električne energije, medtem ko sta s proizvodnjo poleg globalnega sevanja močno povezani povprečna relativna vlažnost in temperatura.

Uporabljali smo strojno učenje za usposabljanje niza podatkov o zgodovinskih vremenskih realiziranih stanjih in napovedi za izpeljavo funkcije, ki napove proizvodnjo električne energije iz sončnih elektrarn za določeno časovno obdobje z nizom napovedanih vremenskih meritev. Oblikovali smo modele, ki temeljijo na večrazsežni linearni regresiji po metodi najmanjših kvadratov.

KLJUČNE BESEDE

napovedovanje, večrazsežna regresijska analiza, električna energija, proizvodnja električne energije, sončne elektrarne, obnovljivi viri energije, vremenski dejavniki, globalno sevanje, modeliranje

TITLE

Forecasting models of electric energy generation from solar power plants

ABSTRACT

The aim of the thesis was to find the relationship between electric energy generation and weather factors. From the obtained results, their interpretations and implications, we designed models for planning the electric energy generation from solar power plants.

The traces of extensive historical data from weather stations were analyzed, as well as the relevant weather forecasts obtained from Agency of the Republic of Slovenia for the environment, so we could connect the weather measurements. Our analysis quantifies how each weather variable affects the other and the global radiation, which is the most influential weather variable in electric energy generation from solar power plants. We found that the wind speed does not have a substantial connection with the electric energy generation, while to generation in addition to global radiation there are strongly related average relative humidity and temperature.

We used machine learning training data set of historical weather realized conditions and forecasts to derive a function, which predicts the electric energy generation from solar power plants for a certain period of time with a set of forecasted meteorological measurements. Models were formulated based on multiple linear least squares regression.

KEYWORDS

forecasting, multiple regression analysis, electric energy, electric energy generation, solar power plants, renewable energy sources, weather factors, global radiation, models

KAZALO

1	UVOD.....	1
2	OPIS GOSPODARSKE DRUŽBE	3
3	ANALIZA VPLIVNIH DEJAVNIKOV NA DELOVANJE FOTOVOLTAIČNIH MODULOV	7
3.1	Vpliv Sončeve energije.....	8
3.1.1	Sevanje na površini Zemlje.....	8
3.1.2	Položaj in navidezno gibanje Sonca.....	8
3.1.3	Elevacijski kot.....	10
3.1.4	Azimutni kot.....	12
3.1.5	Obsevanost in obsev.....	14
3.2	Vpliv temperature	15
3.3	Vpliv relativne vlažnosti.....	16
4	ANALIZA PROIZVODNJE ELEKTRIČNE ENERGIJE.....	17
4.1	Pridobivanje podatkov	17
4.2	Obdelava z geografskim informacijskim sistemom.....	18
4.3	Grafična odvisnost	19
4.4	Podatkovna analiza	21
4.5	Pearsonov koeficient korelacije	26
5	NAČRTOVANJE PROIZVODNJE ELEKTRIČNE ENERGIJE.....	29
5.1	Računska odvisnost in korelacija.....	30
5.2	Vremenska napoved.....	34

5.3	Napoved proizvodnje električne energije	37
5.3.1	Večrazsežna regresijska analiza	37
5.3.2	Drseče povprečje	40
5.4	Statistične metode za merjenje napak	46
5.4.1	MAPE – Povprečna absolutna odstotna napaka.....	47
5.4.2	MAD – Povprečni absolutni odklon	49
6	ZAKLJUČEK	51
7	LITERATURA	53

KAZALO SLIK

Slika 1: Organigram podjetja E 3, d.o.o.	5
Slika 2: Lokacije poslovnih enot družbe E 3, d.o.o. (Kje nas najdete, 2014)	6
Slika 3: Navidezno gibanje Sonca v severni hemisferi (Solar Tracker, 2014)	9
Slika 4: Prikaz položaja Sonca in Lune v realnem času z osvetljenostjo Zemlje (Day and Night World Map, 2014)	9
Slika 5: Elevacijski kot h , zenitni kot z in azimutni kot A (SamsaraLight, 2014)	10
Slika 6: Medletne opoldanske elevacije Sonca na geografskih širinah od 30° do 70° severne poloble in nespremenjeni vzhodni geografski dolžini -15° (Sovič, 2009)....	11
Slika 7: Navidezno gibanje Sonca (elevacija) v odvisnosti od časa (Solar Path, 2014)	11
Slika 8: Medletni opoldanski azimuti Sonca na vzhodnih geografskih dolžinah od -10° do -20° in nespremenjeni geografski širini 46° (Sovič, 2009)	12
Slika 9: Navidezno gibanje Sonca ob letnem in zimskem solsticiju (Sovič, 2009) ...	13
Slika 10: Navidezno gibanje Sonca (azimut) v odvisnosti od časa (Solar Path, 2014)	13
Slika 11: Opoldanska analema nad Greenwichom (Analemma, 2014)	14
Slika 12: Vpliv temperature na karakteristiko sončne celice (Andrejašič, 2007)	15
Slika 13: Grafični prikaz pridobljenih podatkov primernih za obdelavo	18
Slika 14: GIS obdelava: lociranje oznak sončnih elektrarn in meteoroloških postaj.	19
Slika 15: Primer proizvedene električne energije v SE v odvisnosti od globalnega sevanja za mesec november	20
Slika 16: Vrednosti globalnega sevanja v obravnavanem obdobju	22

Slika 17: Vrednosti globalnega sevanja v obravnavanem obdobju ob 12. uri	22
Slika 18: Odvisnost globalnega sevanja od hitrosti vetra	23
Slika 19: Odvisnost globalnega sevanja od povprečne relativne vlažnosti.....	24
Slika 20: Odvisnost globalnega sevanja od temperature.....	24
Slika 21: Odvisnost temperature od povprečne relativne vlažnosti	25
Slika 22: Odvisnost proizvodnje električne energije od globalnega sevanja	26
Slika 23: Regresijska podatkovna analiza.....	31
Slika 24: Grafični prikaz realizacije in napovedi z dvema metodama	34
Slika 25: Vremenska napoved pozimi.....	35
Slika 26: Vremenska napoved pomladi.....	35
Slika 27: Vremenska napoved poleti.....	36
Slika 28: Vremenska napoved jeseni	36
Slika 29: Prikaz napovedi električne energije z drsečim povprečjem.....	37
Slika 30: Primer dvodnevne napovedi	41
Slika 31: Napoved proizvodnje električne energije za zimsko obdobje	42
Slika 32: Odstopanje napovedi proizvodnje od realizirane proizvodnje za zimsko obdobje.....	42
Slika 33: Napoved proizvodnje električne energije za spomladansko obdobje.....	43
Slika 34: Odstopanje napovedi proizvodnje od realizirane proizvodnje za spomladansko obdobje	43
Slika 35: Napoved proizvodnje električne energije za poletno obdobje.....	44

Slika 36: Odstopanje napovedi proizvodnje od realizirane proizvodnje za poletno obdobje.....	44
Slika 37: Napoved proizvodnje električne energije za jesensko obdobje	45
Slika 38: Odstopanje napovedi proizvodnje od realizirane proizvodnje za jesensko obdobje.....	45
Slika 39: Simulacija napovedi proizvodnje električne energije za leto 2013	46

KAZALO TABEL

Tabela 1: Korelacijska matrika med vremenskimi dejavniki.....	28
Tabela 2: Vrednosti MAPE po mesecih.....	48
Tabela 3: Vrednosti MAD po mesecih.....	50

1 UVOD

Energija je bila, je in bo ostala osnovni temelj, ki določa stabilnost gospodarskega razvoja vsakega naroda.

Problem z znatnim vključevanjem obnovljivih virov je, da je proizvodnja električne energije iz obnovljivih virov energije težko predvidljiva vnaprej in se spreminja glede na vremenske razmere in razmere na določenem mestu. Iz tega razloga otežuje vnaprejšnje načrtovanje urnika proizvodnje na omrežju.

Da bi olajšali boljše načrtovanje in znižali ovire za povečanje deleža obnovljivih virov energije v omrežje, smo se osredotočili na problem samodejnega tvorjenja modelov, ki natančno napovejo proizvodnjo električne energije iz obnovljivih virov z vremensko napovedjo Agencije Republike Slovenije za okolje. Konkretno smo eksperimentirali z različnimi tehnikami strojnega učenja za razvoj modelov za napovedovanje z uporabo preteklih napovedanih vremenskih podatkov in jih povezali z merilnimi podatki proizvodnje električne energije iz sončnih elektram. Ustvarjeni modeli uporabljajo tekoče vremenske napovedi Agencije Republike Slovenije za okolje po območjih za napovedovanje proizvodnje v več časovnih obdobjih.

Ker smo ustvarjali modele iz zgodovinskih podatkov o proizvodnji električne energije pomeni, da podatki že zajemajo učinke lokalnih značilnosti, kot na primer naklon sončnih modulov, sence iz okoliških dreves in podobno. Zaradi vpliva lokalnih značilnosti na proizvodnjo električne energije je bilo potrebno modele prilagoditi za vsako določeno lokacijo. Samodejnemu tvorjenju modelov dajemo ključni pomen za povečanje razpršene proizvodnje električne energije iz obnovljivih virov energije na številnih domovih po vsem omrežju.

Ob vprašanju zakaj zdaj so misli najprej utekle h konkurenci, ki je dandanes vse večja. Potrebno se je namreč vseskozi truditi, da je poslovanje kar se da optimalno, zato so v vsakem trenutku dobrodošle kakršnekoli izboljšave. Rezultati diplomskega dela nudijo največjo korist predvsem oddelku za trgovanje z električno energijo. Zasnovani modeli za napovedovanje omogočajo izboljšanje točnosti napovedi proizvodnje električne energije, posledično pa se količinsko optimizira nabava

električne energije. Iz tega sledi tudi stroškovna optimizacija. Modeli so prav tako primerni za napovedovanje proizvodnje za pametne domove, ki vključujejo obnovljive vire v omrežje na kraju samem. Tako omrežje kot tudi posamezne pametne hiše lahko uporabljajo te modele za napovedovanje za vnaprejšnje načrtovanje proizvodnje in porabe električne energije. Omrežje lahko uporablja modele za načrtovanje urnikov odpreme proizvodnje vnaprej, ko se frakcija obnovljivih virov poveča na omrežje. Pametne hiše lahko uporabijo vzorce za potencialno načrtovanje svojih vzorcev potrošnje, za boljšo usklajenost moči, ki jo ustvarjajo na kraju samem. V obeh primerih so boljši modeli za napovedovanje pogoj za povečanje učinkovitosti in spodbujanje širšega sprejetja porazdeljene proizvodnje iz obnovljivih virov v omrežje in na pametne domove.

Diplomsko delo je razdeljeno na več vsebinskih sklopov. V prvem sklopu je opisana družba E 3, energetika, ekologija, ekonomija, d.o.o., ki je znatno prispevala k nastanku pričujočega diplomskega dela z omogočanjem dostopa do potrebnih podatkov.

V drugem sklopu smo za lažje razumevanje podrobneje predstavili Sončevo energijo in analizirali glavne dejavnike, ki vplivajo na delovanje fotovoltaičnih modulov, ki so bili upoštevani pri ustvarjanju modelov. Ti dejavniki so globalno sevanje, vpadni kot Sonca, temperatura in relativna vlažnost.

Tretji sklop smo namenili analizi proizvodnje električne energije. Predstavili smo pridobivanje podatkov, obdelavo podatkov z geografskim informacijskim sistemom, grafično odvisnost proizvodnje električne energije z najvplivnejšo neodvisno spremenljivko, podatkovno analizo z medsebojnimi odnosi in vplivi vremenskih spremenljivk ter Pearsonov koeficient korelacije.

Največji poudarek smo namenili četrtemu sklopu, in sicer napovedovanju proizvodnje električne energije iz sončnih elektrarn. Razdelali smo računsko odvisnost in korelacijo spremenljivk, analizirali vremensko napoved in napoved proizvodnje električne energije. Predstavili smo metodo večrazsežne regresijske analize in drsečega povprečja ter zaključili s statističnimi metodami za merjenje napak.

2 OPIS GOSPODARSKE DRUŽBE

Družba Elektro Primorska d.d. je leta 2004 ustanovila hčerinsko družbo E 3, energetika, ekologija, ekonomija, d.o.o. Skrajšan naziv družbe je E 3, d.o.o.

Zahteve po pravni ločitvi dejavnosti gospodarskih javnih služb od tržnih dejavnosti in proizvodnje so bile glavni vzrok za ustanovitev družbe (Poročilo za leto 2010, 2011). Elektro Primorska d.d. je 100% lastnik družbe.

Sodobna in inovativna gospodarska družba E 3, d.o.o. je na elektroenergetskem področju kakovosten in zanesljiv partner. Družba prepoznava sodobne izzive in priložnosti na energetske področju. Njene glavne dejavnosti so nakup in prodaja električne energije končnim odjemalcem, uvajanje novih tehnologij na področju učinkovite rabe energije, izvajanje različnih projektov obnovljivih virov energije ter trgovanje z ostalimi energenti.

Za opravljanje energetskih dejavnosti s področja proizvodnje električne energije, proizvodnje in distribucije toplote, ter dobavo, trgovanje, zastopanje in posredovanje na trgu z električno energijo ima vse zahtevane licence.

Družbo E 3, d.o.o. odlikuje tradicija in konkurenčnost, energetska učinkovitost, skrb za prihodnost, varnost in cenovna stabilnost ter strokovnost in izkušnje. Že več kot 60 let deluje na področju nakupa in prodaje električne energije. Dobavlja in svetuje pri oskrbi z električno energijo številnim velikim in malim gospodarskim subjektom. V Sloveniji dobavlja električno energijo več kot 105.000 gospodinjskim odjemalcem, trgovanje z električno energijo pa so razširili tudi na mednarodne trge.

V okviru služb za proizvodnjo in storitve se ponaša s številnimi uspešno izpeljanimi projekti kogeneracije. Na področju soproizvodnje toplote in električne energije nudi svetovanje, projektiranje in izvedbo projektov kogeneracije različnih moči.

Pomemben vplivni dejavnik odločanja v družbi je zavzemanje za čim širšo izrabo obnovljivih virov energije. Pohvali se lahko s postavitvijo in priključitvijo prvih malih vetrnih elektrarn na omrežje v Sloveniji. Izmed številnih projektov izgradenj sončnih elektrarn je prav tako postavila prvo fotovoltaično elektrarno v Sloveniji, v kateri je združila sledljivost in zrcala, ter tako povečala njen izkoristek za 30 %.

Kvalificirana je za ponudbo celotnega inženiringa za obnovljive vire energije, med njimi tudi ogrevanje in hlajenje stavb s toplotnimi črpalkami na geosondo.

Družba E 3, d.o.o. je zanesljiv in kakovosten ponudnik električne energije. Poslovni partnerji se nanjo obrnejo glede svetovanja pri celotni energetske oskrbi, načrtovanja sistemov za učinkovito in okolju prijazno oskrbo ter svetovanja in izvedbe sistemov, ki omogočajo optimizacijo porabe električne energije in ostalih energentov. Družba zna prepoznati sodobne izzive in številne priložnosti na energetske področju v svojem okolju (Predstavitev podjetja, 2012).

Stremi k prispevanju k razvoju trga z električno energijo in drugimi energenti doma in na tujem, skrbi za okolje, uvajanju in realizaciji projektov obnovljivih virov energije, učinkoviti in okolju prijazni proizvodnji energije, razvoju širše družbe z osveščanjem in izobraževanjem javnosti ter opozarjanjem na pomen porekla električne energije, ki jo kupujejo. Trudi se kontinuirano zagotavljati vse boljše storitve za dosedanje in nove odjemalce.

V nadaljnje si je družba zadala postati eden od vidnejših igralcev med slovenskimi trgovci z električno energijo in drugimi energenti, v tujini pa postati prepoznaven, majhen ter odziven partner z dobro ponudbo. Zaradi ekološke naravnosti družbe in skrbi o prihodnosti človeštva na našem planetu je vizija družbe ohranjati ekološko ravnovesje med dejavnostjo človeka, življenjem planeta in njegovih ekosistemov. Skrbi za ekonomsko učinkovite in donosne aktivnosti družbe.

Vrednote družbe so skrb za okolje, sodelovanje, inovativnost, izobraževanje in usposabljanje, podjetništvo ter zadovoljstvo odjemalcev (Strateške stalnice, 2014).

Poslovni uspeh družbe temelji na ekonomski racionalnosti, uravnoveženem razvoju in vpetosti v naravo in družbeno okolje. Zavedanje, da je poleg poslovne uspešnosti pomemben tudi odnos do okolja delovanja, je družbo pripeljalo do širjenja načela družbeno odgovornega ravnanja v poslovnem in družbenem okolju. Želi si izboljšati okoljske vidike poslovanja, gospodarno ravnati in pripomoči k racionalnejši rabi energije, surovin ter drugih naravnih virov.

Konkurenčna prednost družbe je vidna v družbeni odgovornosti, saj s pozitivnim odnosom do vseh deležnikov gradijo ugled in nadaljnji razvoj družbe. Dejavnost je na

področju podpore številnih humanitarnih, kulturnih, izobraževalnih, športnih in ostalih projektov s sponzorstvi in donacijami. Dobrodelne aktivnosti razvijajo sami in se pogosto pridružujejo humanitarnim akcijam (Družbena odgovornost, 2014).

Slika 1 prikazuje organiziranost družbe po sektorjih: služba za nakup in prodajo energentov, služba za proizvodnjo in storitve ter splošne službe. Praktično usposabljanje, ki je vodilo v nastanek pričujočega dela, sem opravljala v okviru splošnih služb pod vodstvom Miloša Protića, univ. dipl. inž. el. (vodja splošnih služb, op. p). Deluje na štirih lokacijah (slika 2), in sicer v Novi Gorici, Sežani, Kopru, Tolminu ter skupaj zaposluje 37 oseb.



Slika 1: Organigram podjetja E 3, d.o.o.



Slika 2: Lokacije poslovnih enot družbe E 3, d.o.o. (Kje nas najdete, 2014)

3 ANALIZA VPLIVNIH DEJAVNIKOV NA DELOVANJE FOTOVOLTAIČNIH MODULOV

Poleg učinkovitosti sončnih panelov in njihove velikosti obstajajo tudi drugi dejavniki, ki vplivajo na to, koliko energije bodo sončni moduli proizvedli. Na proizvodnjo električne energije iz sončnih elektrarn vplivajo vremenski dejavniki in sezonska nihanja. Vpadni kot Sonca na sončni panel se spreminja s časom dneva in sezonskimi nihanji. Prav tako pa k manjši učinkovitosti sprejema sončne energije prispevajo oblačni in deževni dnevi.

Fotovoltaične sisteme brez funkcije sledenja je na severni polobli treba postaviti proti jugu. Pozicioniranje kotov je neposredno povezano s kotom širine. Če je lokacija sončne elektrarne 46 stopinj severno od ekvatorja, morajo biti sončni paneli obrnjeni neposredno proti jugu pod kotom 46 stopinj. V primeru, da so sončni paneli nameščeni na streho objekta, je potrebno upoštevati strmino strehe.

Za maksimalno učinkovitost je treba sončne module prilagoditi dvakrat letno. V poletnih mesecih je sonce visoko nad glavo, več sončne svetlobe se da ujeti z nagibanjem sončnih celic pod manjšim kotom. Pozimi pa se sonce premika po nebu pod manjšim kotom, zato je v teh mesecih optimalnejši večji kot nagiba sončnih modulov. Veliki poslovni sistemi imajo solarne sisteme za sledenje, ki samodejno sledijo soncu glede na kot sonca skozi dan. Zaradi visokih stroškov, pa se običajno ne uporabljajo za stanovanjske sončne sisteme.

Visoka temperatura lahko močno zmanjša proizvodnjo električne energije iz sončnih elektrarn. Glede na lokacijo, lahko toplota zmanjša moč od 10 % do 25 %.

Negativen vpliv na proizvodnjo ima tudi senca. Širina vpliva sence je odvisna od vrste sončnih modulov. Če so sončne celice povezane zaporedno, sistem deluje na trenutni ravni najšibkejše celice. Če je torej ena sončna celica zasenčena, negativno vpliva na proizvodnjo v ostalih celicah. Pri odločanju o lokaciji je zato priporočljivo narediti analizo senčenja, da preprečimo padanje senc na sončne celice v času ur z največ sončne svetlobe.

Prav tako sončne celice ne morejo absorbirati svetlobe, ko je površina sončnih celic prekrita z umazanijo, ki se z dežjem ne izpere (Getting the Best Solar Panel Efficiency, 2014).

Na mehanske dejavnike nimamo vpliva in v pričujočem delu predpostavljamo, da se ne spreminjajo. Predpostavljamo torej, da se nakloni sončnih celic skozi opazovano obdobje ne spreminjajo, ne vključujemo morebitnih zasenčitev, umazanij in podobnih vplivnih dejavnikov.

Vplivni dejavniki poleg globalnega sevanja, ki jih lahko predvidimo in vključimo v naše modele, pa so vpadni kot Sonca, temperatura in relativna vlažnost.

3.1 Vpliv Sončeve energije

3.1.1 Sevanje na površini Zemlje

»Del sončne svetlobe, ki pride na Zemljo se odbije nazaj v vesolje, preostali del pa se kot toplota najprej začasno shrani v atmosferi, oceanih ali v zemlji, nato pa kot dolgovalovno sevanje izseva nazaj v vesolje.« (Sovič, 2009, str. 32) Sovič navaja, da je največ toplote izsevane iz ekvatorialnih in puščavskih območij (Sovič, 2009).

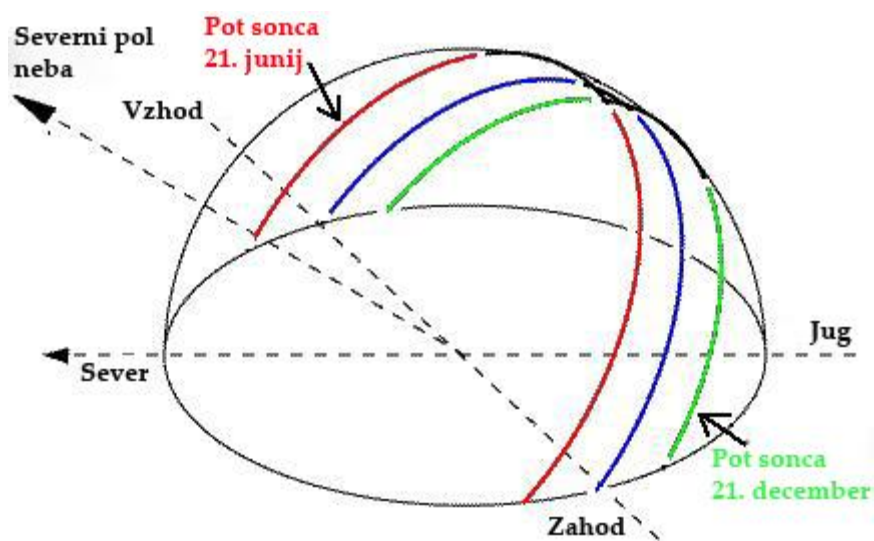
Količina prejete Sončeve energije na zemeljski površini v času ene ure je približno enaka celoletni svetovni rabi energije (Mekhilef in drugi, 2012). »Obsevanost na površini Zemlje je odvisna od atmosferskih efektov, kot sta vpoj in razpršitev, lokalnih atmosferskih značilnosti, kot so vsebnost vodnih hlapov, oblaki in onesnaženje, geografska širina ter letni in dnevni čas. Vsi ti dejavniki vplivajo na velikost obsevanosti in na spekter ter na vpadni kot sevanja.« (Sovič, 2009, str. 33)

3.1.2 Položaj in navidezno gibanje Sonca


Vpadni kot direktne komponente sončne svetlobe se spreminja zaradi Zemljinega vrtenja okoli svoje osi in njenega gibanja okoli Sonca, kar je z opazovane točke na Zemlji vidno kot navidezno gibanje Sonca.

Sončev navidezni položaj je odvisen od geografskih koordinat, dneva in ure. Slika 3 prikazuje navidezno pomikanje Sonca na nebu med dnevom od leve proti desni, navzgor in navzdol glede na horizont ter od sončnega vzhoda do zahoda (Sovič,

2009). Na sliki 3 so nakazane tudi spremembe med vpadnimi koti Sonca v zimskem in poletnem času.



Slika 3: Navidezno gibanje Sonca v severni hemisferi (Solar Tracker, 2014)



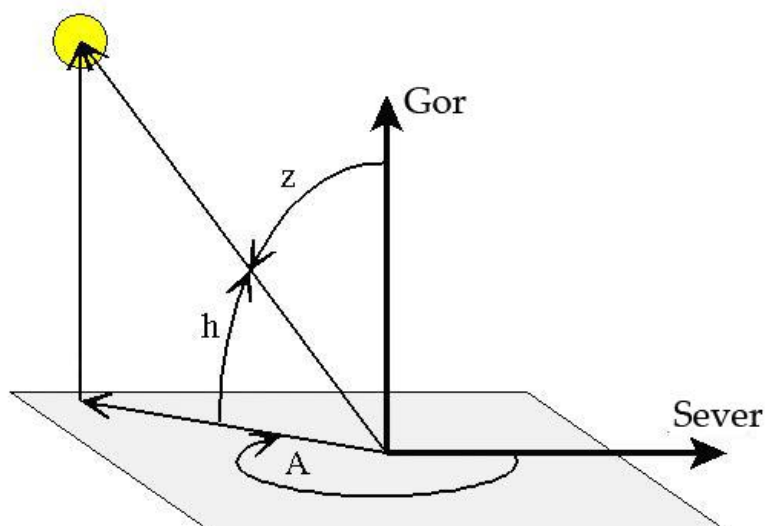
Slika 4: Prikaz položaja Sonca in Lune v realnem času z osvetljenostjo Zemlje (Day and Night World Map, 2014)

Primer položaja Sonca in Lune v realnem času skupaj s trenutno osvetljenostjo Zemlje je prikazan na sliki 4.

3.1.3 Elevacijski kot


Elevacijski kot, tudi altituda ali vpadni kot, prikazan na sliki 5, je kotna razdalja nekega nebesnega telesa od horizonta in je odvisna od kraja, kjer se nahaja opazovalec (Sovič, 2009).

Na sliki 5 so prikazani elevacijski kot (označen s h), ki je merjen s kotno oddaljenostjo nebesnega telesa od horizonta, zenitni kot (označen z z), ki je merjen s kotno oddaljenostjo nebesnega telesa od vertikale in azimutni kot (označen z A), ki je merjen v smeri urinega kazalca od severa. Elevacijski kot in zenitni kot skupaj tvorita pravi kot.



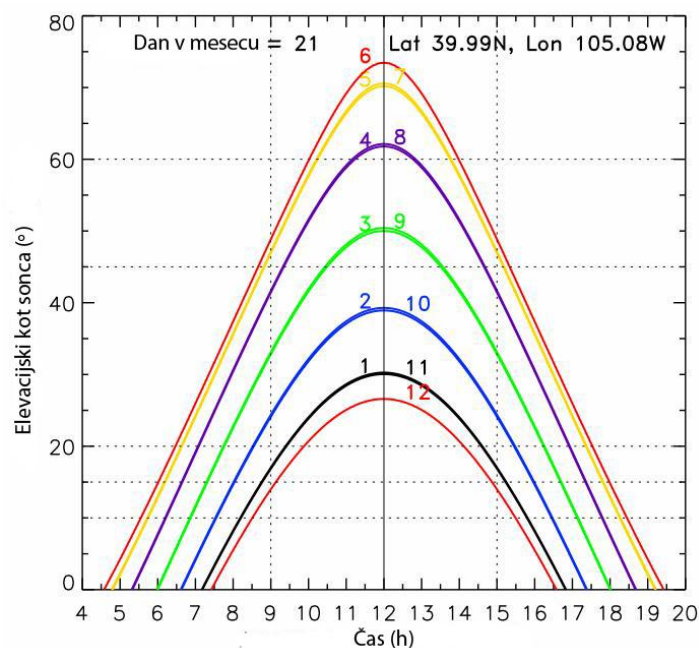
Slika 5: Elevacijski kot h , zenitni kot z in azimutni kot A (SamsaraLight, 2014)

»Elevacija predstavlja skupaj z azimutom koordinato horizontnega koordinatnega sistema, ki izhajajoč iz položaja opazovalca, kot izhodišče pri določanju položaja nebesnih teles uporablja horizont.« (Sovič, 2009, str. 94) Elevacijski kot je odvisen ne le od geografske širine, temveč tudi od dneva v letu in ure, kot je razvidno iz slike 6 (Sovič, 2009).



Slika 6: Medletne opoldanske elevacije Sonca na geografskih širinah od 30° do 70° severne poloble in nespremenjeni vzhodni geografski dolžini -15° (Sovič, 2009)

Slika 7 prikazuje elevacijski kot v odvisnosti od ure za en dan v posameznem mesecu. Mesece predstavljajo številke poleg barvnih linij navideznega gibanja Sonca. Razvidno je, da se elevacijski kot iz meseca v mesec občutno spreminja, kar je vplivalo na odločitev o načinu modeliranja napovedovanja proizvodnje električne energije iz sončnih elektrarn. V praksi si elevacijski kot lahko predstavljamo kot razlog za razliko dolžine senčenja.



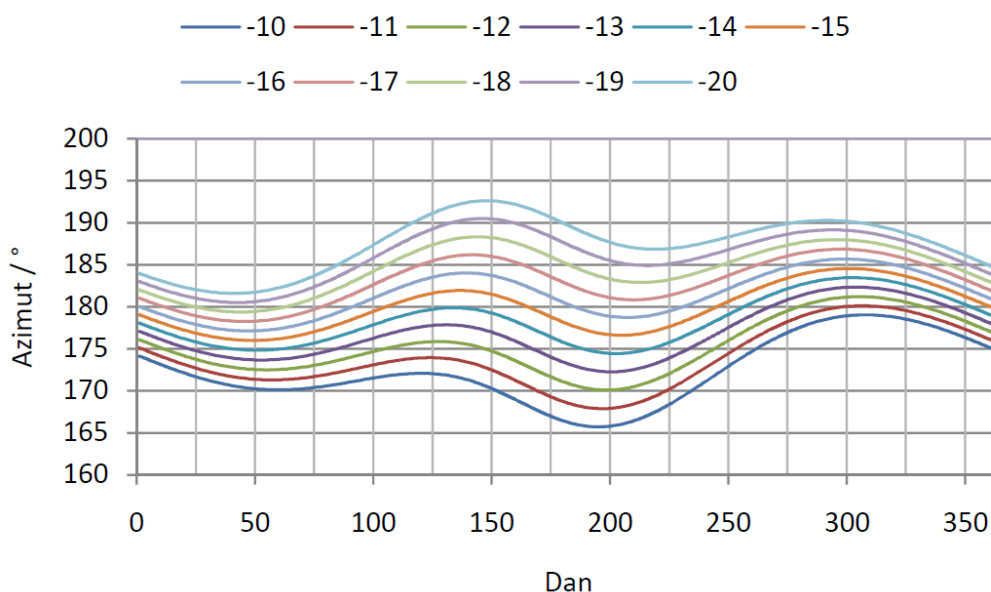
Slika 7: Navidezno gibanje Sonca (elevacija) v odvisnosti od časa (Solar Path, 2014)

3.1.4 Azimutni kot

Kot na nebesni sferi med severom in poldnevnikom skozi Sonce se imenuje azimut (slika 5). Poenostavljeno rečeno, je azimutni kot horizontalna projekcija sončeve poti.

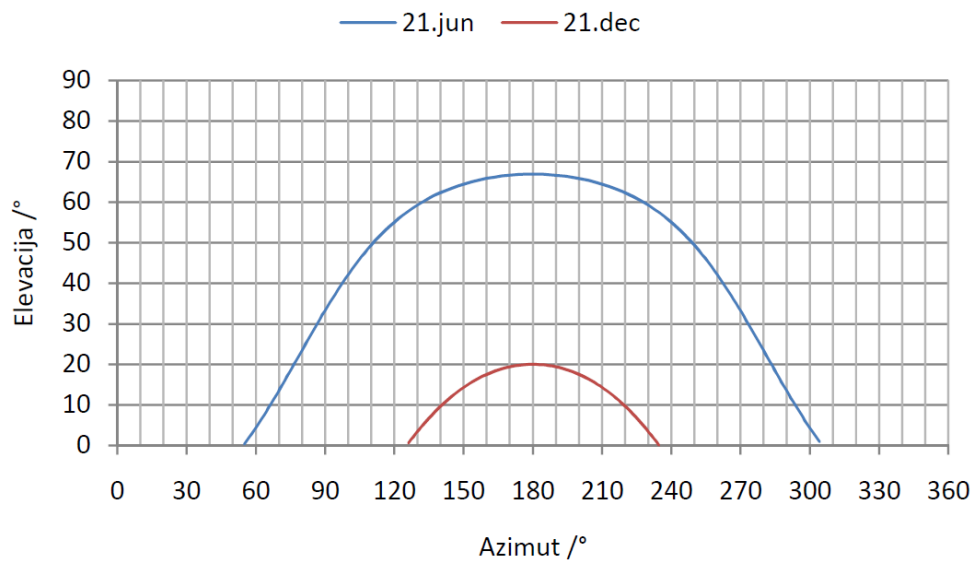
Na severu ima azimut 0° in narašča v smeri urinega kazalca do 360° . Na jugu ima azimut 180° (Sovič, 2009).

Azimutni kot je odvisen ne le od geografske dolžine, temveč tudi od dneva v letu in ure, kot je razvidno iz slike 8.



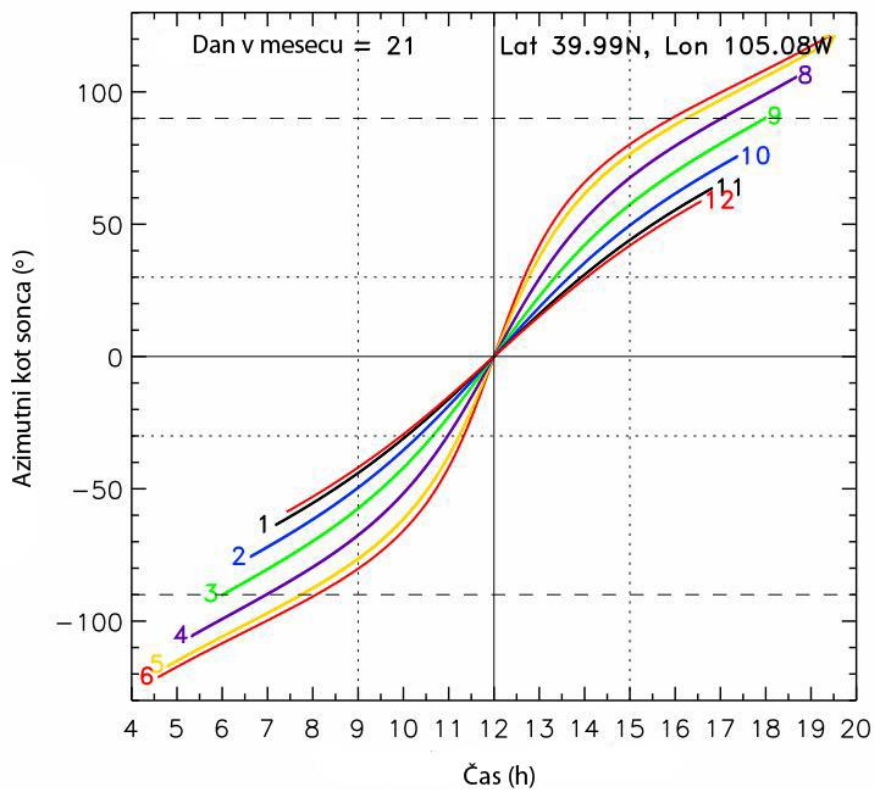
Slika 8: Medletni opoldanski azimuti Sonca na vzhodnih geografskih dolžinah od -10° do -20° in nespremenjeni geografski širini 46° (Sovič, 2009)

Iz analitičnega vidika je najbolj uporabno prikazati ekstremne navidezne položaje Sonca, torej ob obeh solsticijih (21. junija in 21. decembra), kot je prikazano na sliki 9.



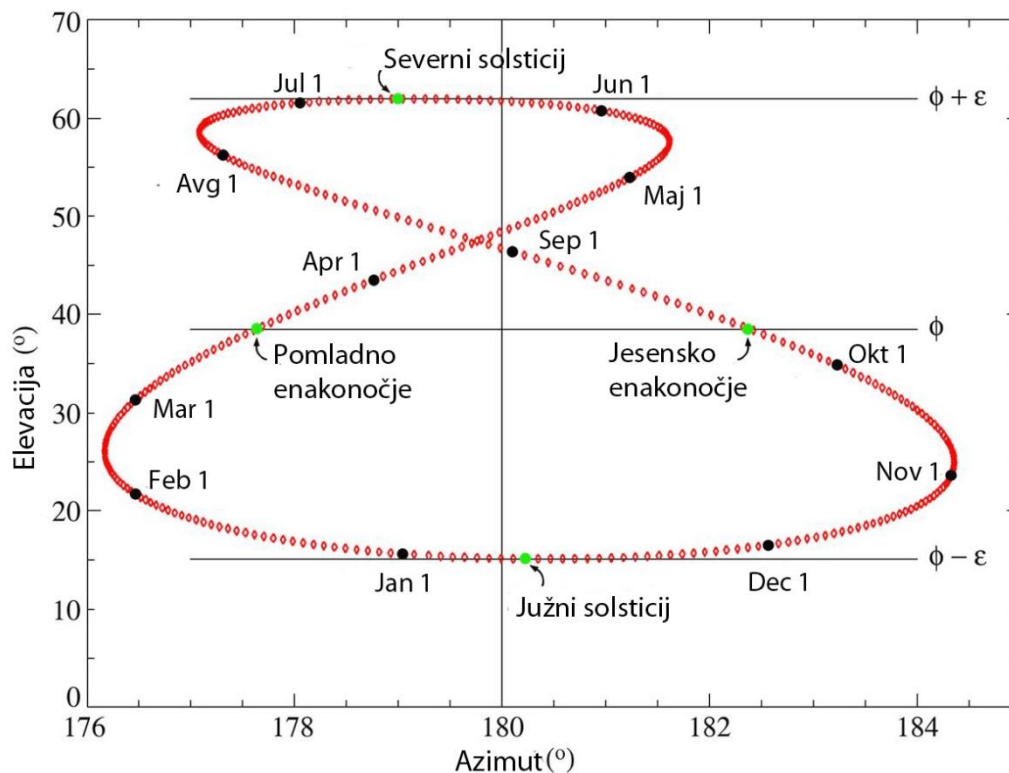
Slika 9: Navidezno gibanje Sonca ob letnem in zimskem solsticiju (Sovič, 2009)

Slika 10 prikazuje azimutni kot v odvisnosti od ure za en dan v posameznem mesecu. Mesece predstavljajo številke poleg barvnih linij navideznega gibanja Sonca. Iz slike so vidne spremembe azimutnega kota skozi celoletno obdobje.



Slika 10: Navidezno gibanje Sonca (azimut) v odvisnosti od časa (Solar Path, 2014)

Analema je linija v obliki osmice, ki jo dobimo tako, da vsak dan med letom ob istem času odčitamo Sončevo lego.



Slika 11: Opoldanska analema nad Greenwichom (Analemma, 2014)

Na sliki 11 je viden grafični prikaz navideznega položaja Sonca ob izbrani uri. Grafični prikaz prikazuje elevacijski kot v odvisnosti od azimutnega kota. Najnižji položaji Sonca so pozimi in najvišji poleti. Najbolj vzhodni položaji Sonca so februarja in marca, najbolj zahodni pa novembra. Na sliki 11 so posebej označeni navidezni položaji Sonca prvega dne v mesecu.

3.1.5 Obsevanost in obsev

»Insolacija (angl. Insolation, Incoming Solar radiation) je skupna količina sončnega sevanja, ki doseže določeno lokacijo.


Obsevanost (angl. Irradiance) je energijski tok v točki na površini, ki vpada na element te površine, deljen s ploščino elementa (W/m^2). Osončenost je obsevanost s sončnim sevanjem.

Obsev (angl. Radiance exposure) je časovni integral obsevanosti, gostota vpadle energije v nekem časovnem obdobju (kWh/m^2 , tudi J/m^2).« (Sovič, 2009, str. 117)

Za potrebe našega dela smo uporabili podatke globalnega sevanja, torej obsevanosti, merjene v W/m^2 .

3.2 Vpliv temperature

Na proizvedeno moč celice ima temperatura celice velik vpliv. Slika 12 prikazuje izrazit vpliv temperature na napetost v celici, ki pada z večanjem temperature (Andrejašic, 2007).



Slika 12: Vpliv temperature na karakteristiko sončne celice (Andrejašic, 2007)

Na obrazcu proizvajalcev sončnih panelov je naveden izraz, običajno opisan kot temperaturni koeficient P_{\max} . Ta vrednost, ki je običajno izražena v obliki negativnega odstotka, razkriva vpliv temperature na panelu.

Sončne celice so preizkušene na 25 °C , tako da odstotek temperaturnega koeficienta prikazuje spremembo učinkovitosti, s pozitivno ali negativno spremembo ene stopinje. Na primer, če je temperaturni koeficient določene vrste panela $-0,5\%$ pomeni, da se bo za vsako naslednjo zvišano 1 °C , največja moč panela zmanjšala za $0,5\%$.

Na vroč dan, ko temperatura panela doseže 45 °C in ima panel temperaturni koeficient -0,5 %, bi bila največja izhodna moč nižja za 10 %. Nasprotno pa, če je bilo sončno zimsko jutro, bodo paneli dejansko bolj učinkoviti.

Vsaka vrsta sončne celice ima drugačen temperaturni koeficient, opisan v nadaljevanju:

- monokristalne in polikristalne celice imajo temperaturni koeficient P_{\max} med -0,45 % do -0,50 %,
- amorfni tankoplastni paneli imajo oceno temperaturnega koeficienta P_{\max} med -0,20 % do -0,25 %,
- hibridne sončne celice, ki so trenutno na trgu, se uvrščajo v sredino s temperaturnim koeficientom P_{\max} okoli -0,32 % (The Impact of Temperature on Solar Panels, 2014).

3.3 Vpliv relativne vlažnosti

Z izpostavljanjem sončnih celic sončni svetlobi, so izpostavljeni tudi vsem naravnim pogojem vključno z dežjem in vlago. Če vlaga uspe prodreti v sončne plošče okvirja, se delovanje fotovoltaičnega modula bistveno zmanjša in lahko privede do stalnega poslabšanja zmogljivosti modulov (Solar panel efficiency, 2014). Kadar je relativna vlažnost nizka, se proizvodnja električne energije iz sončnih elektrarn poveča. Visoka relativna vlažnost pa vpliva na zmanjšanje proizvodnje iz sončnih elektrarn.

4 ANALIZA PROIZVODNJE ELEKTRIČNE ENERGIJE

Poudarek smo dali analiziranju proizvodnje električne energije iz sončnih elektrarn ter vremenskih podatkov za obdobje od leta 2012 do maja 2014. Na podlagi opravljenih analiz je sledilo načrtovanje napovedovanja proizvodnje električne energije v omenjenih elektrarnah v soodvisnosti z vremenskimi napovedmi Agencije Republike Slovenije za okolje.


4.1 Pridobivanje podatkov

Vremenske podatke, sem spadajo povprečna temperatura zraka na dveh metrih, povprečna relativna vlaga, povprečna hitrost vetra in povprečen energijski tok globalnega sevanja, smo za obdobje od januarja 2012 do maja 2014 pridobili iz spletne strani Agencije Republike Slovenije za okolje. Podatki o vremenskih stanjih se za vsako lokacijo obnavljajo v polurnem intervalu. Realizirana stanja vključujejo številne vremenske meritve za vsake pol ure in vsak dan v zadnjih nekaj letih za 48 lokacij po Sloveniji.

Do vremenskih napovedi v krajih Bilje, Bovec, Ilirska Bistrica in Koper smo lahko dostopali preko arhiva zakupljenih podatkov družbe E 3, d.o.o. izvirnega vira Agencije Republike Slovenije za okolje. Vremenske napovedi zagotavljajo podatke z enournim intervalom, zato smo glede na to prilagodili tudi realizirane vremenske podatke.

Merilne podatke proizvodnje električne energije za obdobje od januarja 2012 do maja 2014 pa smo pridobili iz internih podatkov podjetja Elektro Primorska, d.d. Merilni podatki proizvodnje električne energije so bili posredovani v obliki 15-minutnih intervalov, zato smo jih za potrebe diplomskega dela in ujemanje z vremenskimi podatki preoblikovali na urne intervale.

Slika 13 grafično prikazuje pridobljene podatke za obravnavano obdobje z vrednostmi proizvodnje iz samo ene sončne elektrarne.



Slika 13: Grafični prikaz pridobljenih podatkov primernih za obdelavo

4.2 Obdelava z geografskim informacijskim sistemom

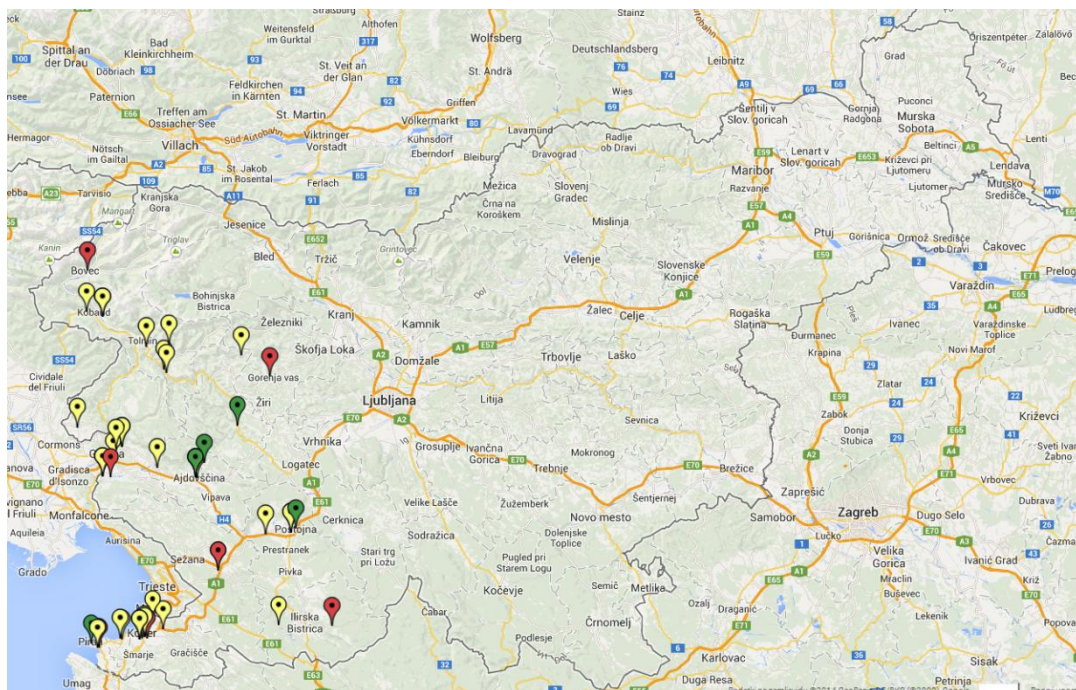
»Geografski informacijski sistem je zbirka tehnoloških orodij za zbiranje, shranjevanje, iskanje, pretvorbe, prikazovanje in obdelave prostorskih podatkov stvarnega sveta.« (Geografski informacijski sistem, 2014)

Z lociranjem sončnih elektrarn in meteoroloških postaj na geografski karti smo v prvi vrsti dosegli analitično obdelavo prostorskih podatkov in hitro vizualno predstavbo z namenom povezave sončnih elektrarn in meteoroloških postaj.

Na sliki 14 predstavljajo rumene oznake sončne elektrarne, ki svojo proizvodnjo električne energije prodajajo podjetju E 3, d.o.o., zelene predstavljajo lokacije meteoroloških postaj Agencije Republike Slovenije za okolje, z rdečo pa so označene tiste meteorološke postaje, kjer se izvajajo meritve povprečnega energijskega toka globalnega sevanja.

Sončnih elektrarn je bilo v mesecu marcu 44, število pa se iz meseca v mesec rahlo spreminja. Na raziskovanem območju je skupno 13 meteoroloških postaj Agencije Republike Slovenije za okolje, od tega je postaj z merilnimi podatki povprečnega energijskega toka globalnega sevanja 6, in sicer v Biljah, Borštu pri Gorenji vasi, Bovcu, Ilirski Bistrici, Kopru in Škocjanu. Za nadaljnjo analizo smo upoštevali štiri,

in sicer v krajih Bilje, Bovec, Ilirska Bistrica in Koper, predvsem iz enega razloga, ker smo imeli vremenske napovedi dostopne samo na navedenih štirih meteoroloških postajah.



Slika 14: GIS obdelava: lociranje oznak sončnih elektrarn in meteoroloških postaj

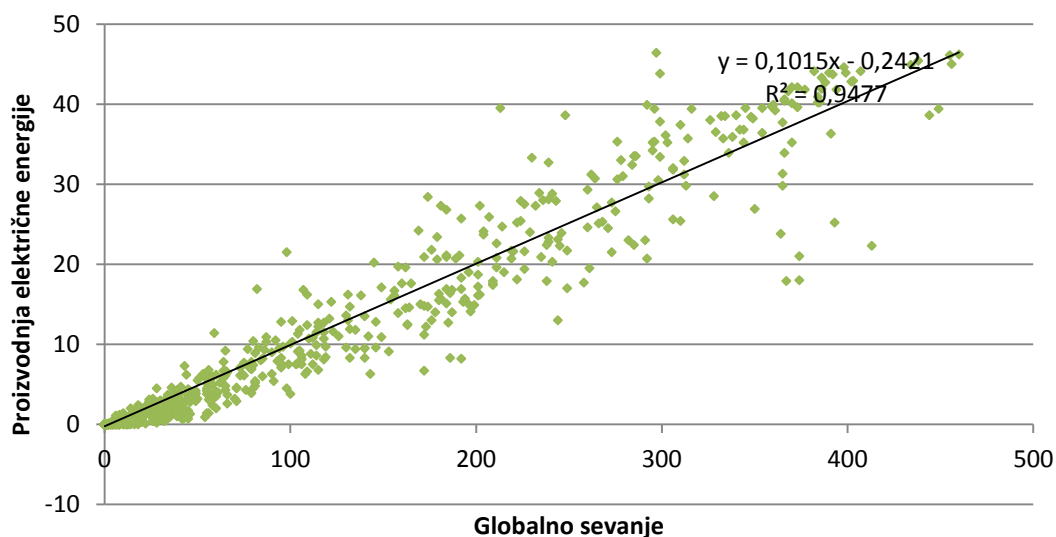
4.3 Grafična odvisnost

Grafična korelacija je omogočila hiter pregled odvisnosti dveh spremenljivk, proizvodnje električne energije v odvisnosti od globalnega sevanja. Tako smo lahko razbrali ali povezava med njima sploh obstaja in izkazalo se je, da sta močno povezani.

Na vsaki enoti smo gledali po dve številski spremenljivki hkrati. Pozornost smo usmerili v relacijo med spremenljivkama (Košmelj, 2007). »Pomembni relaciji sta: odvisnost in povezanost (soodvisnost). Pod pojmom odvisnost razumemo relacijo, kjer vrednosti ene spremenljivke vplivajo na vrednosti druge spremenljivke, v drugo smer pa vpliva ni.« (Košmelj, 2007, str. 145)

Za vsako merilno mesto smo imeli podatke o količini proizvedene električne energije in globalno sevanje v bližnjem okoliškem kraju, kjer se nahaja meteorološka postaja. Sončno obsevanje je neodvisna spremenljivka, njene vrednosti so na abscisni osi,

proizvedena električna energija je odvisna spremenljivka, njene vrednosti so na ordinatni osi.



Slika 15: Primer proizvedene električne energije v SE v odvisnosti od globalnega sevanja za mesec november

Slika 15 kaže, da se s povečevanjem globalnega sevanja povečuje tudi proizvedena električna energija. Slika 15 nakazuje, da je odvisnost linearna. Točke, ki so od oblaka točk vidno odmaknjene, so lahko posledica različnih dejavnikov, ki jih ne moremo predvideti. Sem spadajo morebitna oblačnost, meritvene napake, vzdrževalna dela ipd.

Na osnovi slike in odvisnosti spremenljivke proizvodnje električne energije od spremenljivke globalnega sevanja smo sklepali, da za matematično funkcijo uporabimo model enostavne linearne regresije, opisane z enačbo (1). V opazovani populaciji je vrednost odvisne spremenljivke vsota treh členov: konstante α , večkratnika neodvisne spremenljivke βX in t. i. slučajnih (neznanih, nepojasnjenih) vplivov ε (Košmelj, 2007).

$$Y = \alpha + \beta X + \varepsilon \quad (1)$$

»Količini α in β sta parametra enostavnega linearnega modela. Populacijo predstavlja vzorec velikosti n , na osnovi katerega smo izračunali oceno za α in

oceno za β . Ti dve oceni smo označili a in b .« (Košmelj, 2007, str. 146) Ocena regresijske premice je opisana z enačbo (2).

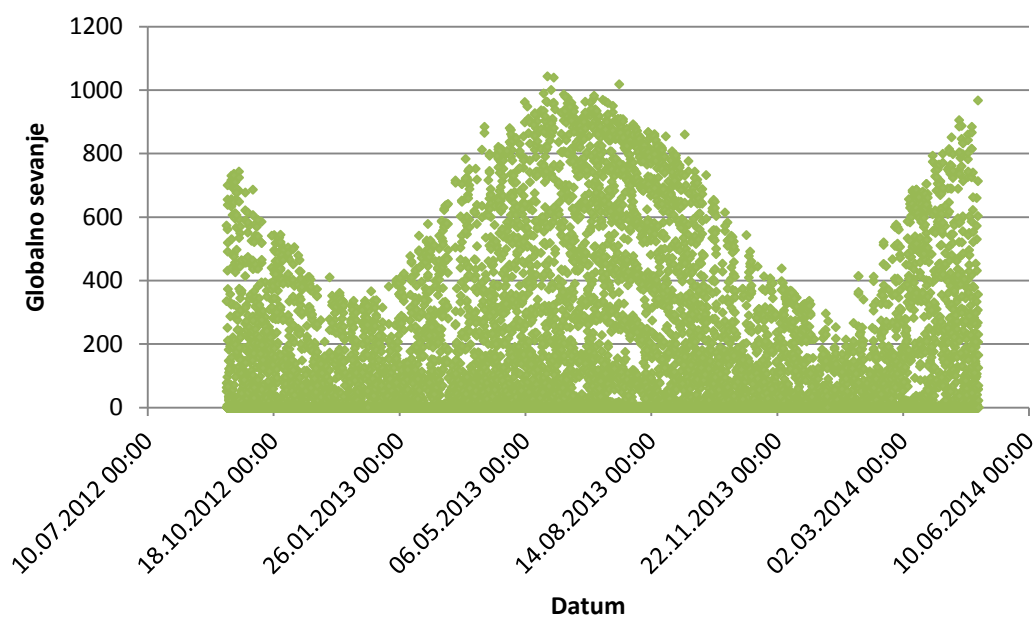
$$Y = a + bX \quad (2)$$

»Premica se mora čim bolj prilagajati točkam. Odkloni točk od premice ($y - y'$) morajo biti čim manjši. Nekateri odkloni so pozitivni, nekateri pa negativni, zato je smiselno odklone kvadrirati. Carl Friederich Gauss (1777-1855) je postavil kriterij, ki pravi, da naj bo premica postavljena tako, da je vsota kvadratov odklonov minimalna.« (Košmelj, 2007, str. 146) Koeficient a predstavlja začetno vrednost funkcije, koeficient b pa njen naklon.

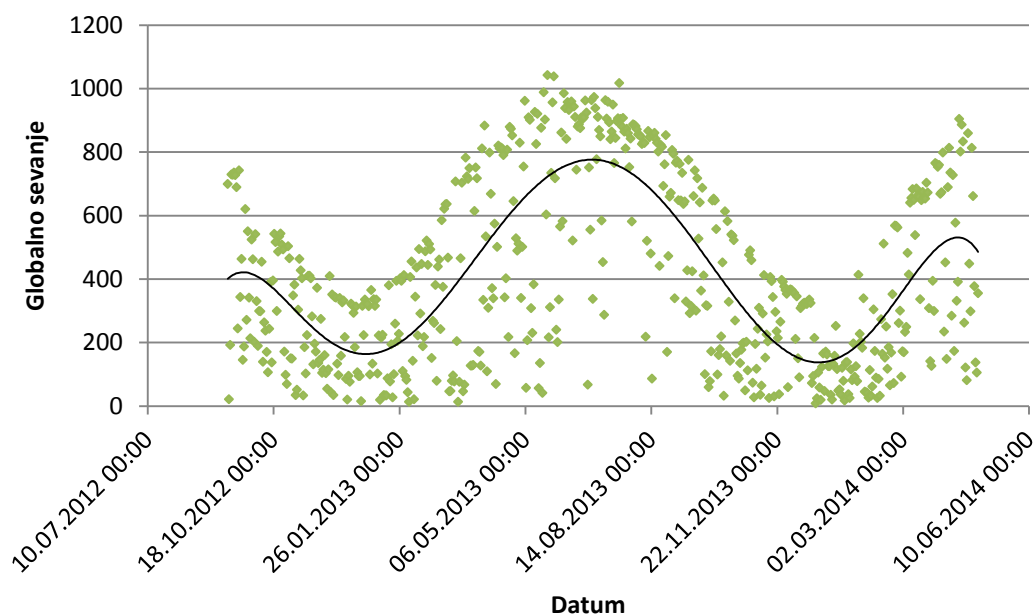
»Regresija je prilagajanje ustrezne matematične funkcije empiričnim podatkom. To funkcijo imenujemo regresijska funkcija.« (Košmelj, 2007, str. 145)

4.4 Podatkovna analiza

Proizvodnja električne energije iz sončnih elektrarn je glede na dognano iz razdelka 4.3 neposredno sorazmerna z globalnim sevanjem. V tem poglavju bomo preučili, kako se globalno sevanje spreminja glede na posamezne vremenske parametre in kako so ti parametri povezani med seboj. Namen naše analize je bil ugotoviti, kako sta globalno sevanje in proizvodnja električne energije iz sončnih elektrarn odvisni od kombinacije različnih vremenskih meritev. Ugotovili smo, da nista zlahka predvidljivi iz ene vremenske spremenljivke. Kompleksnost pri napovedovanju proizvodnje električne energije iz sončnih elektrarn nas je motivirala za nadaljnjo študijo modeliranja napovedovanja z uporabo tehnik strojnega učenja.



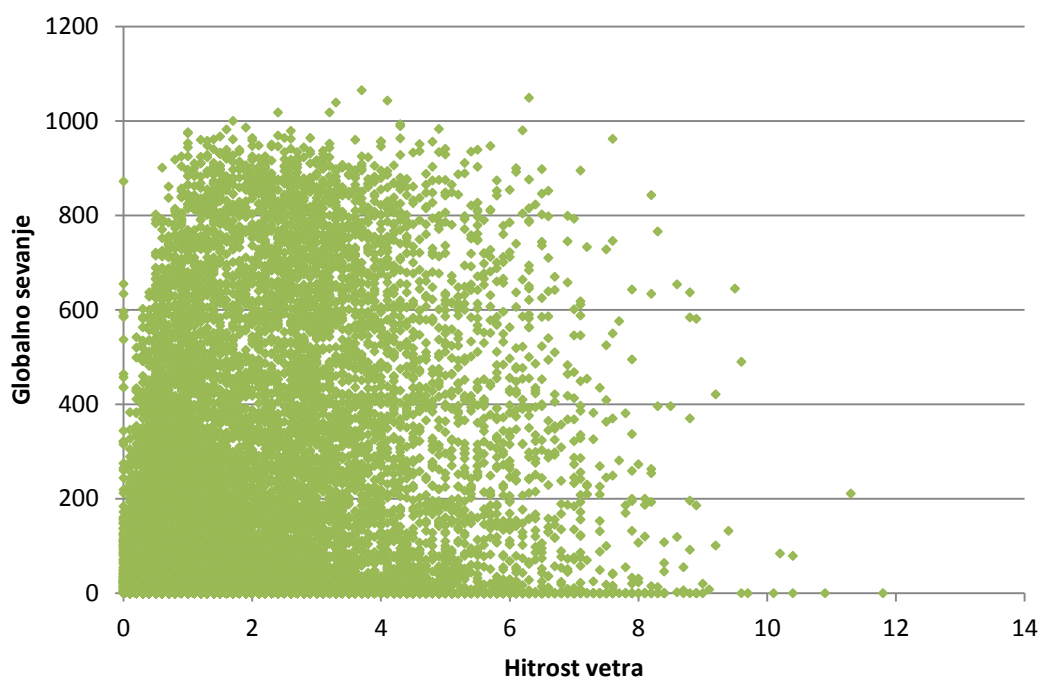
Slika 16: Vrednosti globalnega sevanja v obravnavanem obdobju



Slika 17: Vrednosti globalnega sevanja v obravnavanem obdobju ob 12. uri

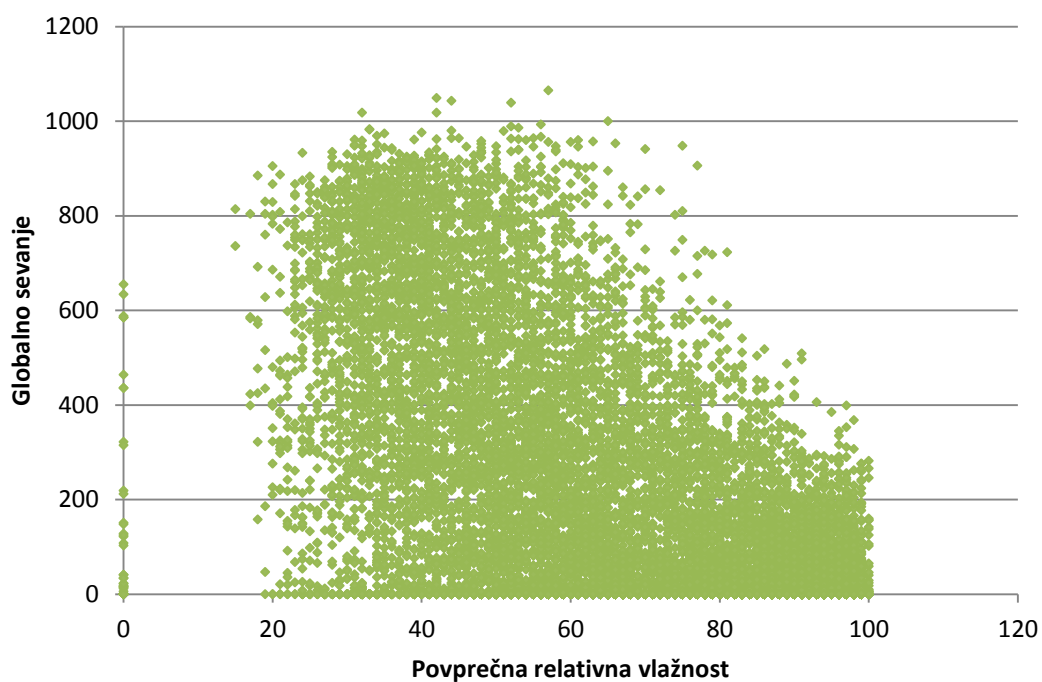
Sliki 16 in 17 prikazujeta vpliv sezone in dneva v letu na globalno sevanje. Na sliki 17 so prikazane vrednosti globalnega sevanja ob 12. uri za določeno obdobje opazovanja. Kot je bilo pričakovati, je iz grafa razvidno, da je globalno sevanje najnižje januarja blizu zimskega solsticija, na najvišje vrednosti pa naraste v poletnih

mesecih in po pomladnem enakonočju ponovno upade na najnižje vrednosti. Iz slike 17 smo razbrali, da tudi drugi pogoji pomembno vplivajo na globalno sevanje, saj imajo številni dnevi spomladi in poleti nizke vrednosti globalnega sevanja. Dejstvo je, da sta globalno sevanje in dan v letu v grobem povezana. Večino časa, vendar ne vedno, imajo poletni dnevi večje vrednosti globalnega sevanja kot zimski dnevi. Vendar pa h količini globalnega sevanja prispevajo tudi drugi dejavniki, saj je bilo v opazovanem obdobju očitno nekaj sončnih zimskih dni, ki so jim bile pripisane višje vrednosti globalnega sevanja v primerjavi z ostalimi meritvami. Zato smo primerjali odnose ostalih vremenskih meritev.




Slika 18: Odvisnost globalnega sevanja od hitrosti vetra

Slika 18 kaže, da hitrost vetra ni povezana z globalnim sevanjem. Globalno sevanje se skoraj enako razlikuje od nižjih do višjih vrednosti pri kateri koli vrednosti hitrosti vetra. Tako ima hitrost vetra skoraj ničelno korelacijo z globalnim sevanjem in njena vrednost nima občutnega vpliva na vrednost globalnega sevanja ali proizvodnjo električne energije iz sončnih elektrarn.



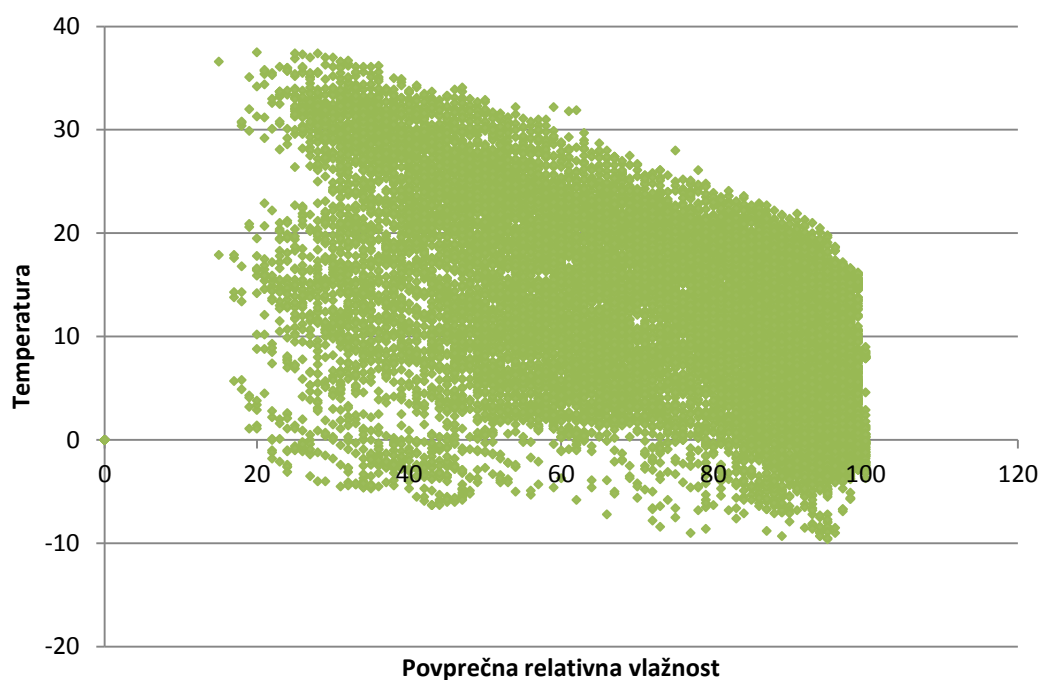
Slika 19: Odvisnost globalnega sevanja od povprečne relativne vlažnosti



Slika 20: Odvisnost globalnega sevanja od temperature

V nasprotju s tem, je iz slik 19 in 20 razvidno, da ima povprečna relativna vlažnost negativno korelacijo z globalnim sevanjem, temperatura pa pozitivno korelacijo z

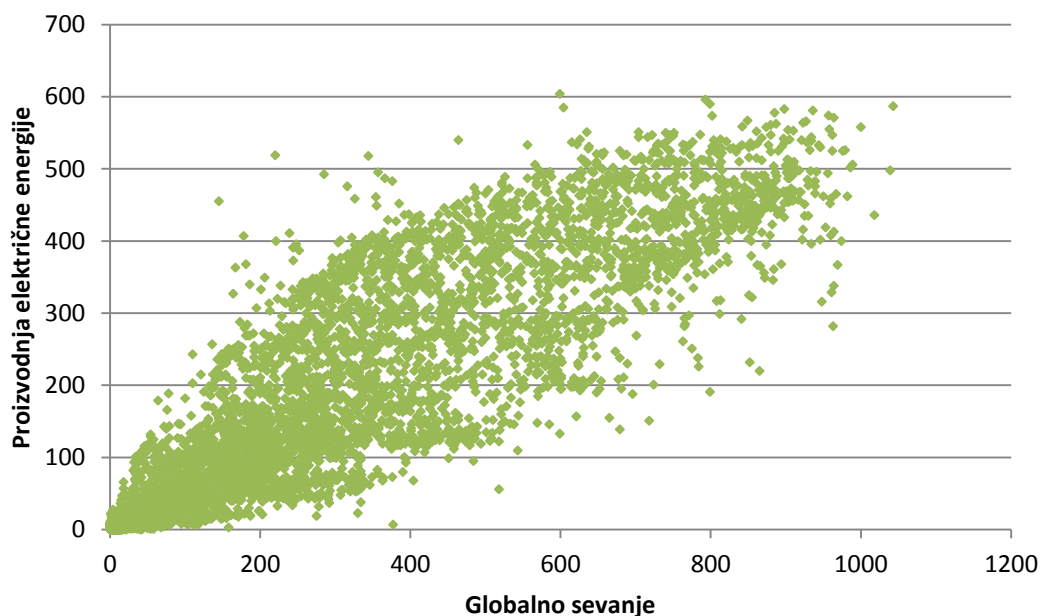
globalnim sevanjem. V prvem primeru, ko se vrednost povprečne relativne vlažnosti poveča, globalno sevanje upade. V drugem primeru pa premo sorazmerno naraščata vrednosti temperature in globalnega sevanja. Poleg dejavnikov temperature in relativne vlažnosti obstajajo še ostali vplivni dejavniki, ki prispevajo k vrednosti globalnega sevanja, kot na primer oblačnost, padavine, temperatura rosišča in podobne. Poleg kompleksnih odnosov obravnavanih spremenljivk z globalnim sevanjem, smo preverili tudi odnose meritev vplivnih dejavnikov med seboj. Slika 21 prikazuje odnos temperature s povprečno relativno vlažnostjo, ki nakazuje korelacijo med spremenljivkama.



Slika 21: Odvisnost temperature od povprečne relativne vlažnosti

4.5 Pearsonov koeficient korelacije

V pričujočem delu smo predpostavili linearne odvisnosti spremenljivk, zato smo za določanje povezanosti spremenljivk uporabljali Pearsonov koeficient korelacije. Linearno odvisnost globalnega sevanja in proizvodnje električne energije za celotno opazovano obdobje prikazuje slika 22.



Slika 22: Odvisnost proizvodnje električne energije od globalnega sevanja

»Pearsonov koeficient korelacije je matematična in statistična številska mera, ki predstavlja velikost linearne povezanosti spremenljivk X in Y , merjenih na istem predmetu preučevanja.« (Pearsonov koeficient korelacije, 2014) Koeficient, prikazan z enačbo (3), je definiran kot vsota vseh produktov standardnih odklonov obeh vrednosti v razmerju s stopnjami prostosti oziroma kot razmerje med kovarianco in produktom obeh standardnih odklonov, kjer je z_x z-vrednost spremenljivke globalnega sevanja, z_y z-vrednost spremenljivke proizvodnje električne energije, N pa število vseh statističnih enot.

$$r_{xy} = \frac{\sum z_x z_y}{N-1} \quad (3)$$

Drugi način izračuna je predstavljen z enačbo (4), kjer je C_{xy} kovarianca, σ_x standardni odklon spremenljivke globalnega sevanja, σ_y pa standardni odklon spremenljivke proizvodnje električne energije.

$$r_{xy} = \frac{C_{xy}}{\sigma_x \sigma_y} \quad (4)$$

Dobljeni rezultat je eden izmed kvadratnih korenov, ki je lahko pozitiven ali negativen, koeficienta determinacije r_{xy}^2 , ki je razmerje med pojasnjeno varianco in skupno varianco, prikazano z enačbo (5), kjer je Y dejanska vrednost dane spremenljivke proizvodnje električne energije, Y' pa predvidena vrednost iste spremenljivke proizvodnje električne energije ob znani korelaciji med globalnim sevanjem in proizvodnjo električne energije ter vrednosti globalnega sevanja.

$$r_{xy}^2 = \frac{\sum(Y' - \bar{Y})^2}{\sum(Y - \bar{Y})^2} \quad (5)$$

Pearsonov koeficient korelacije ima vrednost med -1 in 1, kjer -1 predstavlja popolno negativno povezanost spremenljivk, pri čemer je na grafu odvisnosti videti le ravno črto, ki z naraščajočo neodvisno spremenljivko potuje navzdol. Vrednost 1 pa pomeni popolno pozitivno povezanost in navzgor usmerjeno črto na grafu. Popolno funkcijsko odvisnost -1 ali 1 je v praktičnem preizkušanju odvisnosti in uporabni statistiki skoraj nemogoče izračunati, saj na posamezno odvisno spremenljivko vpliva praviloma več dejavnikov, med njimi tudi slučajni vplivi. V primeru vrednosti Pearsonovega koeficienta 0 pomeni, da vpliv ene spremenljivke na drugo ne obstaja (Pearsonov koeficient korelacije, 2014).

Vrednost Pearsonovega koeficienta korelacije spremenljivk globalnega sevanja in proizvodnje električne energije za opazovano obdobje (slika 22) je 0,935542, kar nakazuje zelo močno povezanost.

Z linearno regresijsko analizo je moč izračunati enačbo, ki najbolje opisuje linearno odvisnost dveh ali več spremenljivk. Dobljena enačba je ob visokih vrednostih Pearsonovega koeficienta najbolj natančna (Pearsonov koeficient korelacije, 2014).

Tabela 1: Korelacijska matrika med vremenskimi dejavniki

	Temperatura	Povprečna relativna vlažnost	Hitrost vetra	Globalno sevanje
Temperatura	1			
Povprečna relativna vlažnost	-0,447740072	1		
Hitrost vetra	0,114018554	-0,51695787	1	
Globalno sevanje	0,535044039	-0,594776079	0,240720026	1

Tabela 1 prikazuje korelacijske koeficiente za vsako vremensko spremenljivko z uporabo Pearsonovega koeficienta korelacije, ki ločuje kovarianco dveh spremenljivk z zmnožkom njihovih standardnih odklonov. Višja kot je absolutna vrednost koeficienta korelacije, močnejša je povezava med dvema vremenskima spremenljivkama. Pozitivna korelacija predstavlja naraščajoč linearni odnos, medtem ko negativna korelacija padajoč linearni odnos.

5 NAČRTOVANJE PROIZVODNJE ELEKTRIČNE ENERGIJE

V današnjih kompleksnih in nepredvidljivih časih je vedno bolj pomembno napovedovanje delovanja poslovanja. Danes, bolj kot kdajkoli, morajo menedžerji na vseh nivojih pripraviti inteligentne napovedi prihajajoče prodaje in trende dobička, kot del njihove celotne poslovne strategije.

Poslovno napovedovanje se pojavlja že več let, razvite so bile številne metode, nekatere bolj, druge manj uspešne. V pričujočem delu smo uporabljali tehniko regresijske analize. Regresija je močen statistični postopek in je postala priljubljeno poslovno orodje. V splošnem se regresijska analiza uporablja za določanje odnosa med dvema odvisnima pojavoma. Odvisen pojav se imenuje odvisna spremenljivka oziroma y-vrednost, drugemu pojavu pa pravimo neodvisna spremenljivka oziroma x-vrednost.

Iz podatkov teh dveh spremenljivk lahko z regresijsko analizo določimo odnos med poznanimi x- in y-vrednostmi, rezultate pa uporabimo za izračun in vizualizacijo skupnega trenda podatkov ter uporabimo obstoječe trende za napoved novih y-vrednosti.

Najbolj uporabljena tipa regresijske analize v poslovanju sta enostavna regresija (linearna, nelinearna – najpogosteje polinomska) in regresija z več spremenljivkami.

Z linearnimi podatki je odvisna spremenljivka povezana z neodvisno spremenljivko s konstantnim faktorjem. Za pridobitev regresijske funkcije v programskem orodju Excel je na voljo več različnih metod, in sicer s trendno črto, s funkcijo TREND(), s funkcijo LINEST() in podrobnejšo regresijsko podatkovno analizo. (Paul McFedries, 2004)

Spremljali smo tako realizirane kot tudi napovedane vremenske meritve kot časovne vrste, ki se spreminjajo zaradi spreminjajočih se vremenskih razmer in letnih časov. V razdelku 4.4 smo dokazali, da je globalno sevanje odvisno od različnih vremenskih spremenljivk, kar otežuje nalogo priprave natančnega modela za napovedovanje. Visoka dimenzionalnost podatkov v časovni vrsti je motivirala našo študijo regresijskih metod za razvoj modelov za napovedovanje proizvodnje električne energije iz sončnih elektrarn. Ena izmed prednosti uporabe strojnega učenja za

samodejno ustvarjanje modelov za napovedovanje je, da se s povečevanjem količine podatkov izboljšuje tudi natančnost modela.

V pričujočem delu smo se osredotočili na kratkoročne napovedi proizvodnje električne energije iz sončnih elektrarn po urah. Napovedi lahko zaradi vsebine dnevno pridobljenih podatkov zajemajo največ tridnevno napoved proizvodnje. ARSO namreč dnevno posreduje vremenske podatke za dan pošiljanja in dvodnevno napoved.

5.1 Računska odvisnost in korelacija

Z računsko odvisnostjo in korelacijo smo želeli z regresijsko analizo potrditi ali ovreči odvisnost proizvodnje električne energije od globalnega sevanja, ki smo jo razbrali iz grafične korelacije.

Najprej smo podatke o proizvodnji razdelili po mesecih ločeno po merilnih mestih. Delitev na posamezne mesece izhaja v izogib vpliva vpadnega sončnega kota, opisanega v poglavju 3.1, ki ima na proizvodnjo električne energije iz sončnih elektrarn občuten vpliv. Vpadni kot sonca se spreminja iz ure v uro, zato smo regresijsko funkcijo izračunali za skupek enakih ur v posameznem mesecu. Za eno merilno mesto je torej potrebnih 288 regresijskih funkcij. Na sliki 23 je prikazan primer regresijske podatkovne analize za 15. uro v februarju. Iz regresijske podatkovne analize je poleg koeficientov neodvisnih spremenljivk in začetne vrednosti možno razbrati še kopico drugih podatkov.

SUMMARY OUTPUT						
<i>Regression Statistics</i>						
Multiple R	0,943148089					
R Square	0,889528318					
Adjusted R Square	0,883154952					
Standard Error	49,31055409					
Observations	56					
<i>ANOVA</i>						
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>	
Regression	3	1018103,481	339367,827	139,5696221	7,34898E-25	
Residual	52	126439,5987	2431,530744			
Total	55	1144543,08				
	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>
Intercept	58,27591254	46,34084685	1,257549581	0,214173155	-34,71379975	151,2656248
X Variable 1	2,067729336	2,241950415	0,922290396	0,360636728	-2,431073301	6,566531973
X Variable 2	-1,258752838	0,540114757	-2,330528508	0,023692351	-2,342572388	-0,174933287
X Variable 3	0,840345855	0,074555127	11,2714697	1,41946E-15	0,690740048	0,989951663

Slika 23: Regresijska podatkovna analiza

Prvi del regresijske podatkovne analize je regresijska statistika. Izračunani podatki predstavljajo, kako se izračunana linearna enačba prilagaja danim podatkom.

Koeficient korelacije (angl. Multiple R) pove kako močno je linearno razmerje. Podrobneje je opisana v poglavju 4.5. R^2 je koeficient determinacije (angl. R Square). Pove, koliko točk leži na regresijski premici. Rezultat 0,89 pomeni, da je 89 % variacij y -vrednosti okoli sredine predstavljenih z x -vrednostmi. Iz tega sledi, da 89 % vrednosti ustreza modelu (Excel Regression Analysis Output Explained, 2014). Koeficient determinacije je v splošnem drugotnega pomena, razen v primeru, da je z regresijsko enačbo namen izvesti natančne napovedi (Interpreting Regression Output, 2014). Prilagojeni koeficient determinacije (angl. Adjusted R Square) izračun prilagodi glede na število izrazov v modelu. Navadno se ga uporablja namesto koeficienta determinacije, če je v regresijsko analizo vključenih več spremenljivk, torej v primeru večrazsežne regresijske analize. Pomen rezultata vrednosti prilagojenega koeficienta determinacije se enači z vrednostjo koeficienta determinacije. Standardna napaka regresije (angl. Standard Error) je ocena standardnega odklona napake μ in ni enaka standardni napaki v opisni statistiki. Ne nazadnje je prikazano še število opazovanj v vzorcu (angl. Observations).

Drugi del regresijske podatkovne analize je tabela ANOVA ali analiza variance. Kratica SS pomeni vsota kvadratov (angl. Sum of Squares). Regresijska povprečna

kvadratna napaka (angl. Regression Mean Square Error) se izračuna kot vsota kvadratov regresije deljeno s stopinjami svobode regresije (angl. Degrees of Freedom), ki so v tabeli označene z df. Povprečna kvadratna napaka, označena s kratico MS, se izračuna kot preostala vsota kvadratov deljeno s preostalimi stopinjami svobode. Oznaka F predstavlja celoten F test za ničelno hipotezo, ki ji sledi povezana P-vrednost (angl. Significance F).

Opisan drugi del regresijske podatkovne analize se v primerjavi z regresijsko statistiko redkeje uporablja. V omenjenem drugem delu se statistika na pomenljiv način težje uporablja in predstavlja, saj je vsota kvadratov razdeljena na posamezne dele. Za osnovne modele linearne regresije zadostuje prvi del izpisane regresijske podatkovne analize.

Tretji del regresijske podatkovne analize pa je predstavitev regresijskih koeficientov. Ta del tabele vsebuje natančne informacije o spremenljivkah, izbranih za podatkovno analizo.

Tretjo tabelo sestavlja šest stolpcev. Prvi je koeficienti (angl. Coefficients), ki poda oceno najmanjših kvadratov (Excel Regression Analysis Output Explained, 2014). V preprosti ali večrazsežni linearni regresiji velikost koeficienta vsake neodvisne spremenljivke pove velikost njenega vpliva na odvisno spremenljivko, predznak koeficienta pa pove smer vpliva. Pri večrazsežni regresijski analizi koeficient pove, za koliko se spremeni odvisna spremenljivka, medtem ko se neodvisna poveča za ena in so ostale neodvisne spremenljivke upoštevane kot konstante (Interpreting Regression Output, 2014). Standardna napaka (angl. Standard Error) je ocena standardne napake najmanjših kvadratov. T statistika (angl. T Statistic) se uporablja za ničelno hipotezo v primerjavi z nadomestno hipotezo (Excel Regression Analysis Output Explained, 2014). T statistika se izračuna kot koeficient deljeno s standardno napako. Standardna napaka je ocena standardnega odklona koeficienta. To si lahko predstavljamo kot merilo za natančnost, s katero se meri regresijski koeficient (Interpreting Regression Output, 2014). P-vrednost (angl. P Value) poda vrednost testa hipoteze (Excel Regression Analysis Output Explained, 2014). P-vrednost nakaže korelacijo vsake neodvisne spremenljivke z odvisno spremenljivko. Za analizo je pomembna P-vrednost za regresijo kot celoto. Neodvisne spremenljivke med seboj lahko korelirajo, kar se imenuje multikolinearnost, zato lahko pride do

nepomembnosti vrednosti koeficientov posameznih neodvisnih spremenljivk, medtem ko se koeficienti v regresiji kot celoti skladajo. Razlog je v visoki korelaciji neodvisnih spremenljivk, ki pojasnjujejo isti del variabilnosti odvisne spremenljivke, zato so njihova pojasnjevalna moč in pomen koeficientov porazdeljeni (Interpreting Regression Output, 2014). Ne nazadnje sta predstavljeni še spodnja (angl. Lower 95%) in zgornja meja intervala zaupanja (angl. Upper 95%). Mejo lahko v nastavitvah regresijske podatkovne analize nastavimo na željeno vrednost.

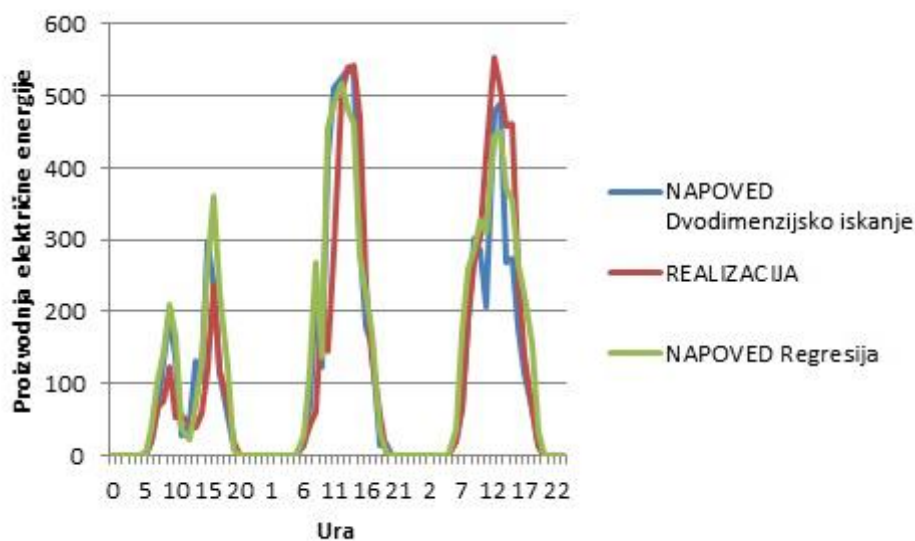
Najopaznejši koristen vidik tega dela analize je možnost razbiranja linearne regresijske enačbe. Iz slike 23 tako lahko razberemo linearno regresijsko enačbo (6) (Excel Regression Analysis Output Explained, 2014).

$$y = 2,0677x_1 - 1,2588x_2 + 0,8403x_3 + 58,2759 \quad (6)$$

Več podrobnosti o opisani statistični analizi in uporabljenih orodjih so opisane v knjigi Essentials of Business Statistics (Bowerman in drugi, 2004).

Zaradi obsega podatkov je metoda dela z regresijsko podatkovno analizo dolgotrajna, zato smo napisali funkcijo, ki na podlagi danih podatkov in določenih obsegov samodejno izračuna vse regresijske funkcije.

Do problema smo pristopili še z nekoliko bolj inženirskega vidika. Želeli smo, da funkcija za napovedano globalno sevanje po urah poišče enake oziroma najbližje manjše vrednosti v bazi realiziranih stanj. Iz baze pa nato vrne podatek o takratni proizvodnji. Funkcijo smo razvili v Microsoftovem okolju in jo poimenovali Dvodimenzijsko iskanje.



Slika 24: Grafični prikaz realizacije in napovedi z dvema metodama


Slika 24 prikazuje primer napovedi za tridnevno obdobje z dvema različnima metodama v primerjavi z realizacijo. Korelacijski koeficient med napovedjo z inženirskim pristopom in realizacijo je 0,900435. Korelacijski koeficient med napovedjo z regresijo in realizacijo pa 0,899856.

Korelacijski koeficient pomaga ugotoviti razmerje med dvema lastnostma. Izvemo torej koliko je podoben trend dveh funkcij. Zaradi razmeroma majhne razlike smo se odločili nadaljevati načrtovanje proizvodnje električne energije samo z regresijsko analizo.


5.2 Vremenska napoved

Vremenske prognoze ne morejo biti do potankosti točne, napaka se običajno večja z dolžino napovedi. Za potrebe diplomskega dela smo predvideli enodnevno napoved, zato se vremenske napovedi bolj približajo kasnejšemu realiziranemu stanju.


Izbrali smo eno naključno tedensko obdobje za vsak letni čas in izračunali korelacijski koeficient. Korelacijski koeficienti med napovedanim in dejanskim globalnim sevanjem znašajo za izbrano obdobje pozimi 0,785401, pomladi 0,847317, poleti 0,950122 in jeseni 0,803847. Iz dobljenih rezultatov lahko razberemo, da so trendi med omenjenima vrednostma povezani. Za lažjo predstavbo smo opisane vrednosti prikazali z grafi na sliki 25, 26, 27 in 28.




Slika 25: Vremenska napoved pozimi



Slika 26: Vremenska napoved pomladi



Slika 27: Vremenska napoved poleti

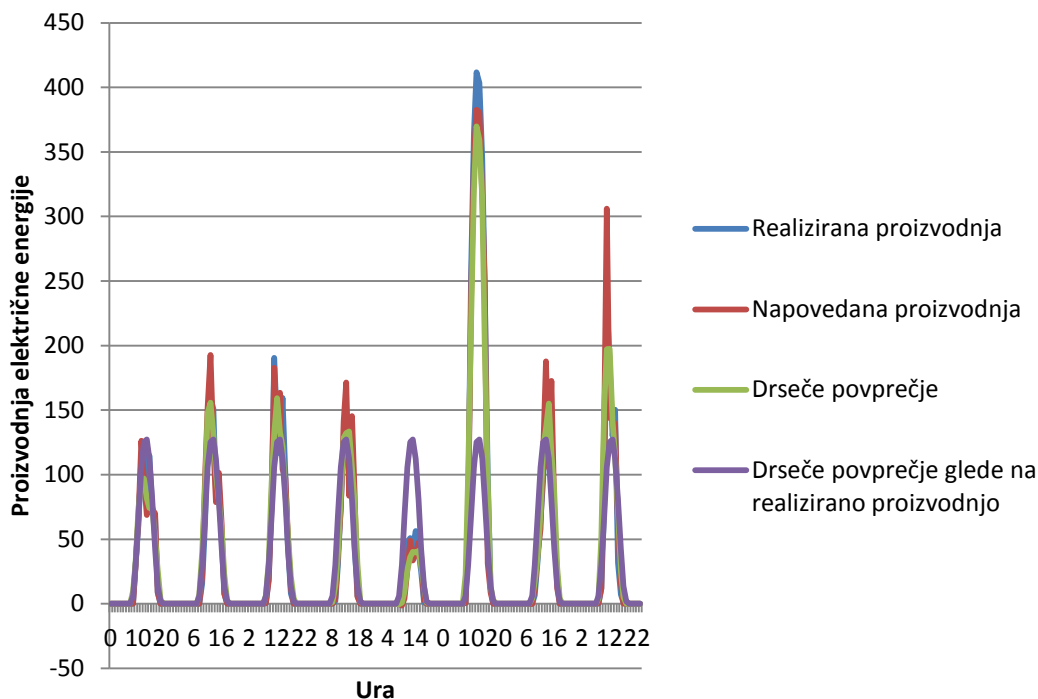


Slika 28: Vremenska napoved jeseni

5.3 Napoved proizvodnje električne energije

Za napovedovanje proizvodnje električne energije iz sončnih elektrarn glede na vremenske podatke smo se odločili za uporabo večrazsežne regresijske analize, ki zajema tri neodvisne spremenljivke: povprečen energijski tok globalnega sevanja, povprečno temperaturo na dveh metrih in povprečno relativno vlažnost.

Metoda napovedovanja z drsečim povprečjem glede na realizirane vrednosti (slika 29) se za namen diplomskega dela ni izkazala za primerno, saj ne upošteva vrednosti dejanskih napovedi, temveč temelji samo na podatkih proizvodnje električne energije iz preteklosti. Metoda kot taka bi bila kvečjemu uporabna za dolgoročno napovedovanje.



Slika 29: Prikaz napovedi električne energije z drsečim povprečjem

5.3.1 Večrazsežna regresijska analiza

V sodobni znanosti je regresijska analiza nujen del v praktično skoraj vsakem procesu združevanja podatkov (Orlov, 1996).

Večrazsežna regresija je analiza več kot enega niza podatkov, ki pogosto ustvarja bolj realistično projekcijo. Koncept regresije se morda sliši čudno, ker je izraz običajno povezan s pogledom nazaj, medtem ko se v svetu statistike regresija pogosto uporablja za napovedovanje prihodnosti. Preprosto povedano, regresija je statistična tehnika, ki najde matematični izraz, ki najbolje opisuje vrsto podatkov (Perform a regression analysis, 2014).

Regresijska analiza uporablja bolj zapletene enačbe za analizo večjih nizov podatkov in jih pretvori v koordinate na črto ali krivuljo. V ne tako daljni preteklosti, se regresijska analiza ni uporabljala pogosto, predvsem zaradi velikega obsega vpletenih izračunov. Ko so programska orodja za delo s preglednicami, kot je Excel, začeli ponujati vgrajene regresijske funkcije, je uporaba regresijske analize postala bolj razširjena (Perform a regression analysis, 2014).

Priljubljeni programi za delo s preglednicami, kot so Quattro Pro, Microsoft Excel in Lotus 1-2-3, zagotavljajo celovite statistične programske pakete, ki poleg drugih vključujejo regresijsko orodje (Orlov, 1996). Za statistično regresijsko analizo smo se odločili za delo s programskim orodjem Excel.

»Linearna regresija več spremenljivk oziroma multipla linearna regresija je posplošitev linearne regresije ene same neodvisne spremenljivke. Vzorec je običajno podan z vrednostmi X_{ij} , $i = 1, \dots, n$, $j = 1, \dots, k$ neodvisnih spremenljivk in ustrezne vrednosti Y_i , $i = 1, \dots, n$ spremenljivke Y . Linearni model zapišemo z enačbo (7), kjer ε , podobno kot pri linearni regresiji ene spremenljivke, predstavlja odstopanje od modela. Običajno predpostavimo, da je ε porazdeljen normalno s pričakovano vrednostjo nič in standardno deviacijo σ .« (Turk, 2011, str. 199-200)

$$Y = Y' + \varepsilon = a + b_1X_1 + b_2X_2 + \dots + b_kX_k + \varepsilon \quad (7)$$

Regresijsko enačbo za posamezni element vzorca X_{ij} , Y_i zapišemo z izrazom (8) (Turk, 2011).

$$Y_i = a + b_1X_{i1} + b_2X_{i2} + \dots + b_kX_{ik} + \varepsilon_i = a + \sum_{j=1}^k b_jX_{ij} + \varepsilon_i \quad (8)$$

»Z regresijo želimo določiti ocene neznanih regresijskih parametrov a in b_j tako, da bodo odstopanja dejanskih vrednosti Y_i od modela čim manjša. Uporabimo metodo najmanjših kvadratov.« (Turk, 2011, str. 200) Minimum funkcije iščemo z enačbo (9).

$$S(a, b_j) = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Y_i - a - \sum_{j=1}^k b_j X_{ij})^2 \quad (9)$$

Omenjeni minimum funkcije določimo tako, da jo odvajamo po a in b_j ter postavimo pogoj, da so ti odvodi enaki nič, kot prikazujejo enačbe (10), (11), (12) in (13) (Turk, 2011).

$$\frac{\partial S}{\partial a} = \sum_{i=1}^n 2(Y_i - a - b_1 X_{i1} - b_2 X_{i2} - \dots - b_k X_{ik})(-1) = 0 \quad (10)$$

$$\frac{\partial S}{\partial b_1} = \sum_{i=1}^n 2(Y_i - a - b_1 X_{i1} - b_2 X_{i2} - \dots - b_k X_{ik})(-X_{i1}) = 0 \quad (11)$$

$$\frac{\partial S}{\partial b_2} = \sum_{i=1}^n 2(Y_i - a - b_1 X_{i1} - b_2 X_{i2} - \dots - b_k X_{ik})(-X_{i2}) = 0 \quad (12)$$

⋮

$$\frac{\partial S}{\partial b_k} = \sum_{i=1}^n 2(Y_i - a - b_1 X_{i1} - b_2 X_{i2} - \dots - b_k X_{ik})(-X_{ik}) = 0 \quad (13)$$

Po preureditvi enačb (10), (11), (12) in (13) dobimo sistem $k + 1$ linearnih enačb za $k + 1$ neznanu oceno parametrov a in b_j (14), (15), (16) in (17). Ta sistem normalnih enačb lahko zapišemo v matrični obliki (Turk, 2011).

$$na + \sum_{i=1}^n X_{i1} b_1 + \sum_{i=1}^n X_{i2} b_2 + \dots + \sum_{i=1}^n X_{ik} b_k = \sum_{i=1}^n Y_i \quad (14)$$

$$\sum_{i=1}^n X_{i1} a + \sum_{i=1}^n X_{i1}^2 b_1 + \sum_{i=1}^n X_{i2} X_{i1} b_2 + \dots + \sum_{i=1}^n X_{ik} X_{i1} b_k = \sum_{i=1}^n Y_i X_{i1} \quad (15)$$

$$\sum_{i=1}^n X_{i2} a + \sum_{i=1}^n X_{i1} X_{i2} b_1 + \sum_{i=1}^n X_{i2}^2 b_2 + \dots + \sum_{i=1}^n X_{ik} X_{i2} b_k = \sum_{i=1}^n Y_i X_{i2} \quad (16)$$

⋮ ⋮ ⋮ ⋮ ⋮

$$\sum_{i=1}^n X_{ik} a + \sum_{i=1}^n X_{i1} X_{ik} b_1 + \sum_{i=1}^n X_{i2} X_{ik} b_2 + \dots + \sum_{i=1}^n X_{i^2 k} b_k = \sum_{i=1}^n Y_i X_{ik} \quad (17)$$

Kadar se ukvarjamo s povezanostjo odvisne spremenljivke Y in z več kot eno neodvisno spremenljivko, recimo k , X_1 , ..., X_k , govorimo o večrazsežni regresijski analizi. V našem primeru smo upoštevali tri neodvisne spremenljivke, in sicer globalno sevanje, povprečno temperaturo na dveh metrih ter povprečno relativno vlažnost.

5.3.2 Drseče povprečje

V statistiki je drseče povprečje izračun za analizo podatkovnih točk z ustvarjanjem več povprečij različnih delov celotnega nabora podatkov.

Glede na serijo števil in fiksno velikost podmnožice, je prvi element drsečega povprečja pridobljen s povprečjem začetne fiksne podskupine serije števil. Potem se podmnožica spremeni tako, da se izloči prvo številko v podmnožici in vključi naslednjo številko prvotne podmnožice v seriji. To ustvarja novo podmnožico števil za izračun povprečja. Ta postopek se ponavlja skozi celotno serijo podatkov. Črta, ki povezuje vsa povprečja je drseče povprečje. Drseče povprečje je niz števil, od katerih vsako povprečje pripada ustrezni podmnožici večjega sklopa referenčnih točk.

Drseče povprečje se običajno uporablja s časovno vrsto podatkov za glajenje kratkoročnih nihanj in poudarjanje dolgoročnih trendov ali ciklov. Poenostavljeno gledano ga je mogoče uporabljati za glajenje oziroma izravnavanje podatkov (Moving average, 2014).

Na področju znanosti in tehnike se povprečje običajno izračuna iz enakega števila podatkov na obeh straneh središčne vrednosti (Moving average, 2014). V pričujočem delu smo drseče povprečje računali na podlagi triurnih podatkov. Za eno povprečje smo torej v obravnavo vzeli podatke o napovedani proizvodnji prejšnje ure, trenutne ure in sledeče ure. Izračunamo ga z enačbo (18), kjer x_n predstavlja vrednost napovedi za uro določeno z n .

$$\text{Drseče povprečje} = \frac{x_{n-1} + x_n + x_{n+1}}{3} \quad (18)$$

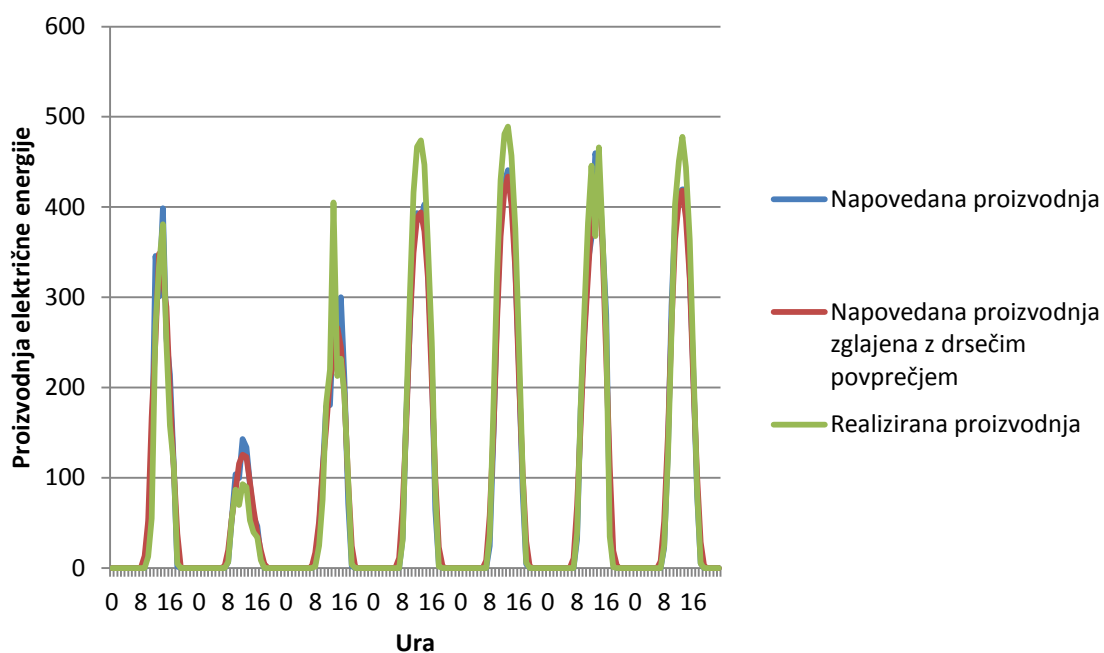
Z drsečim povprečjem lahko izgledimo vrednosti, dobljene z metodo regresije (slika 30). Z metodo drsečega povprečja smo po regresijski analizi izračunali nove vrednosti za posamezne ure, ki so dobile lastnosti ene ure prej in ene ure kasneje. Ker je čas zvezen in napovedi niso točne, se tako nekoliko bolj izognemo velikim skokom vrednosti (slika 32, 34, 36, 38).

Korelacijski koeficienti med napovedano in realizirano proizvodnjo so visoki, in sicer za zimsko obdobje (slika 31) 0,98782253, spomladansko (slika 33) 0,99166384, poletno (slika 35) 0,99808417 in ne nazadnje jesensko (slika 37) 0,95784442.

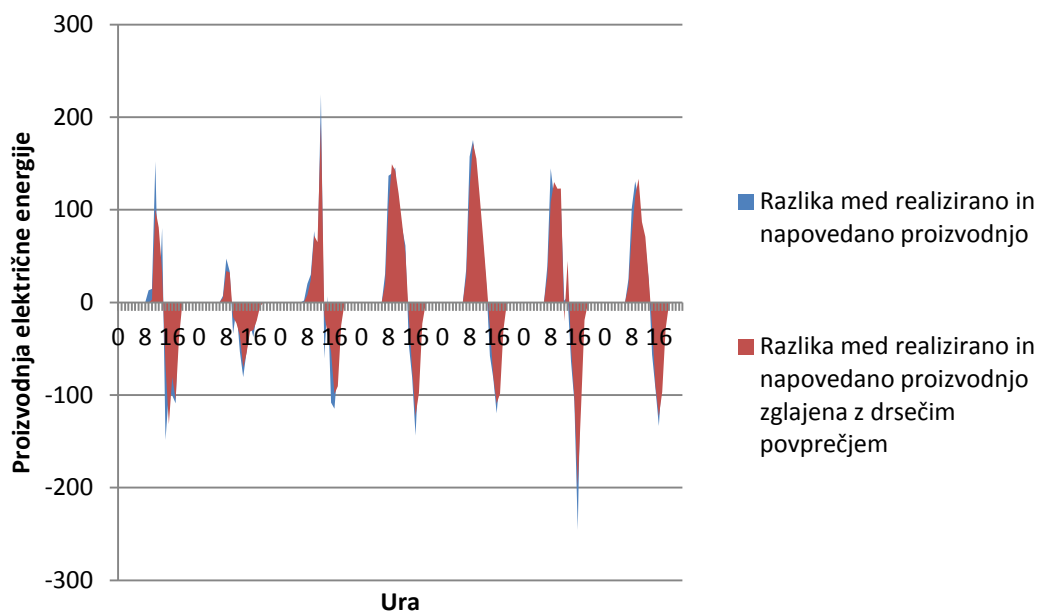
Korelacijski koeficienti med napovedano proizvodnjo zglajeno z drsečim povprečjem in realizirano proizvodnjo so prav tako visoki, z minimalno razliko v primerjavi s prej naštetimi. Za zimsko obdobje (slika 31) 0,985238, spomladansko (slika 33) 0,988123, poletno (slika 35) 0,997007 in ne nazadnje jesensko (slika 37) 0,958239. Za predstavljene rezultate smo izbrali naključna tedenska obdobja v posameznem letnem času. Na slikah 32, 34, 36 in 38 so nazorneje prikazana odstopanja napovedi od realizirane proizvodnje za predstavljena naključna obdobja.

Ura	k _{Crob. sev.}	k _{Rel. vlaž.}	k _{Temp.}	n	Temperatura	Rel. vlažnost	Globalno sevanje	Napovedana proizvodnja	Napovedana proizvodnja zglajena z drsečim povprečjem
0	0	0	0	0	7,4	52	0	0	0
1	0	0	0	0	7,9	46	0	0	0
2	0	0	0	0	7,9	44	0	0	0
3	0	0	0	0	8,3	39	0	0	0
4	0	0	0	0	8,1	40	0	0	0
5	0	0	0	0	8,2	39	0	0	0
6	0	0	0	0	6,4	64	0	0	0
7	0,071733	2,51E-05	0,00194	-0,02688	4,7	79	0	0	0
8	0,428011	0,003035	0,287023	-5,48606	3,9	84	5	0	2,430243084
9	0,732449	-0,13271	-0,2143	-2,67808	4	84	30	7,290729253	22,68752637
10	0,901966	0,060416	0,295031	-46,3475	4,7	78	112	60,77184987	94,49974624
11	0,869269	-0,616	4,519734	-20,8294	6,8	53	274	215,4366596	209,281466
12	0,760206	-1,46473	3,654693	69,75648	8,5	40	407	351,6358884	339,3901874
13	0,687794	-2,90389	3,104279	176,19	10	29	477	451,0980142	389,4361936
14	0,793131	-1,76416	3,549491	97,54924	10,6	29	355	365,5746782	376,6288774
15	0,840346	-1,25875	2,067729	58,27591	10,9	25	314	313,21394	285,6675739
16	1,025629	-0,35253	0,701821	-2,01678	11,2	26	177	178,2141035	178,0355002
17	1,000822	-0,32628	0,376734	17,2287	9,1	46	37	42,67845714	74,02746088
18	1,670634	-0,02917	0,244856	0,925053	6,8	48	0	1,189822056	14,62275973
19	0	0	0	0	3,6	72	0	0	0,396607352
20	0	0	0	0	2,6	78	0	0	0
21	0	0	0	0	1,7	83	0	0	0
22	0	0	0	0	0,5	88	0	0	0
23	0	0	0	0	-0,2	91	0	0	0
0	0	0	0	0	-0,5	92	0	0	0
1	0	0	0	0	-0,4	92	0	0	0
2	0	0	0	0	-0,2	92	0	0	0
3	0	0	0	0	-0,1	91	0	0	0
4	0	0	0	0	0	92	0	0	0
5	0	0	0	0	0,3	90	0	0	0
6	0	0	0	0	0,6	86	0	0	0
7	0,071733	2,51E-05	0,00194	-0,02688	0,8	86	0	0	0,927574974
8	0,428011	0,003035	0,287023	-5,48606	1,1	82	18	2,782724923	29,31317746
9	0,732449	-0,13271	-0,2143	-2,67808	2,3	74	134	85,15680745	91,06697013
10	0,901966	0,060416	0,295031	-46,3475	5,8	58	251	185,261378	201,6496607
11	0,869269	-0,616	4,519734	-20,8294	8,7	50	399	334,5307967	302,0351977
12	0,760206	-1,46473	3,654693	69,75648	9,8	45	456	386,3134183	366,215738
13	0,687794	-2,90389	3,104279	176,19	9,8	50	460	377,8029992	376,0446252
14	0,793131	-1,76416	3,549491	97,54924	9,8	53	410	364,0174581	334,6208363
15	0,840346	-1,25875	2,067729	58,27591	9,7	53	298	262,0420516	256,7756056
16	1,025629	-0,35253	0,701821	-2,01678	9	51	154	144,2673072	147,2436384
17	1,000822	-0,32628	0,376734	17,2287	8,2	58	34	35,42155625	60,09337851
18	1,670634	-0,02917	0,244856	0,925053	6,5	66	0	0,591272098	12,00427612
19	0	0	0	0	4,7	72	0	0	0,197090699
20	0	0	0	0	2,7	81	0	0	0
21	0	0	0	0	1,7	86	0	0	0
22	0	0	0	0	0,7	89	0	0	0
23	0	0	0	0	-0,3	91	0	0	0

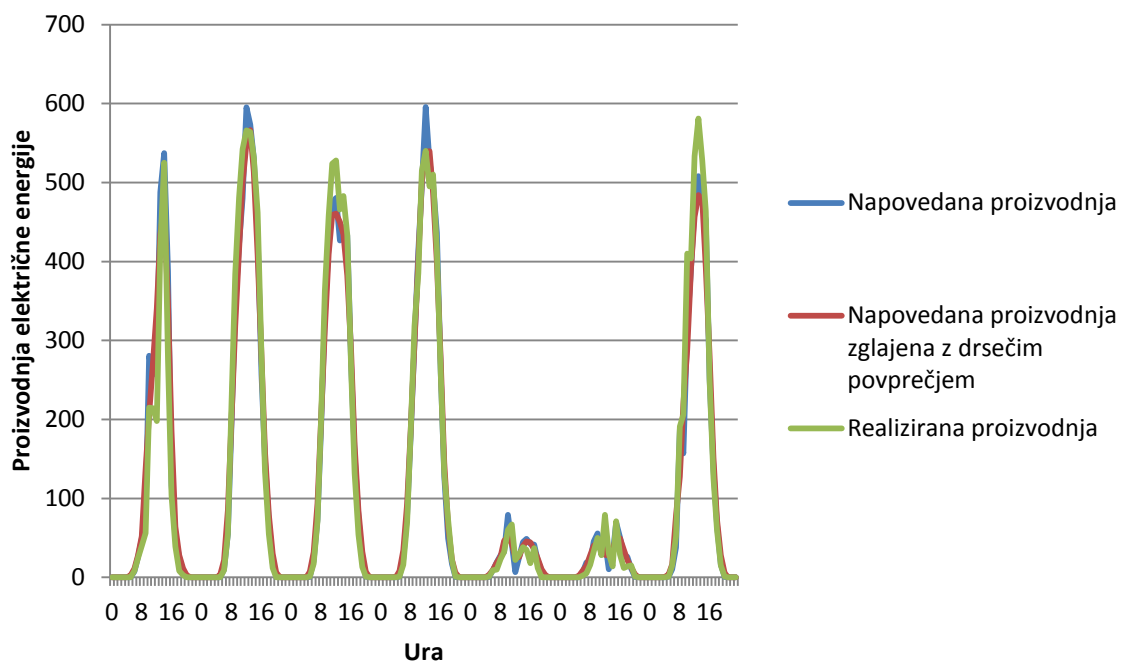
Slika 30: Primer dvodnevne napovedi



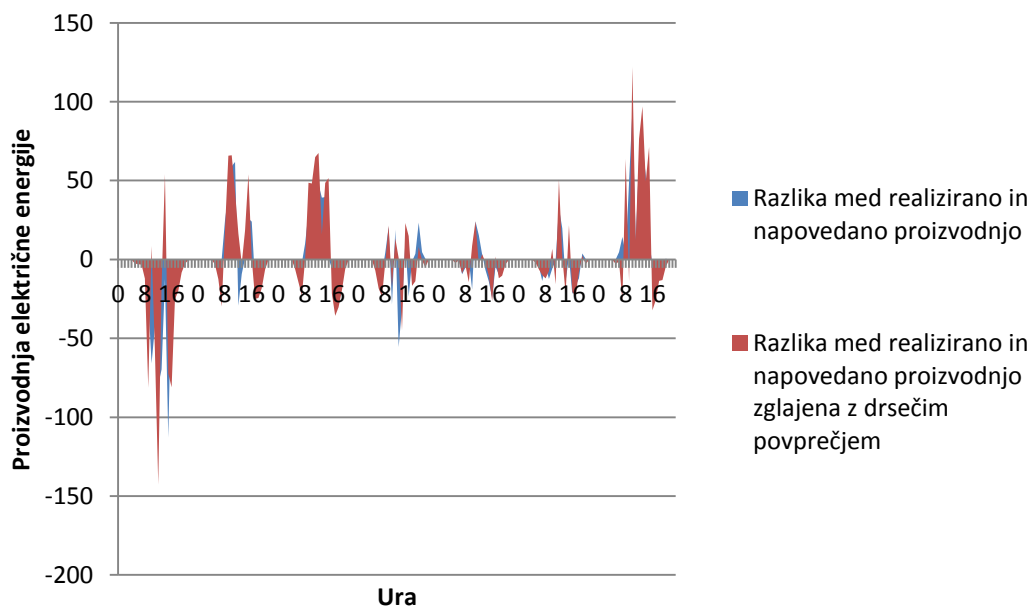
Slika 31: Napoved proizvodnje električne energije za zimsko obdobje




Slika 32: Odstopanje napovedi proizvodnje od realizirane proizvodnje za zimsko obdobje




Slika 33: Napoved proizvodnje električne energije za spomladansko obdobje



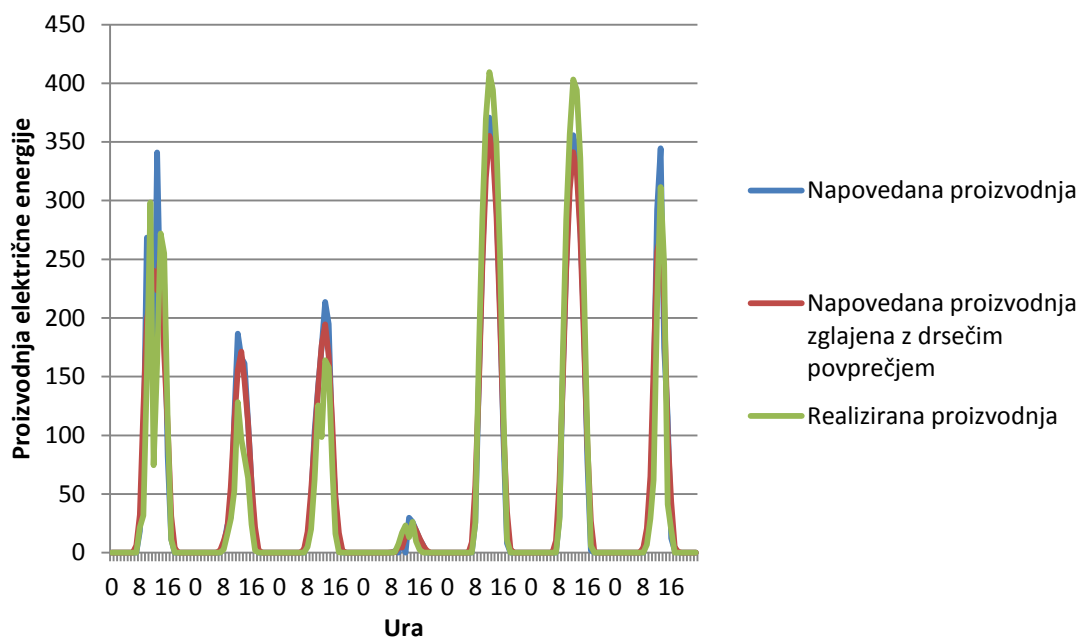
Slika 34: Odstopanje napovedi proizvodnje od realizirane proizvodnje za spomladansko obdobje



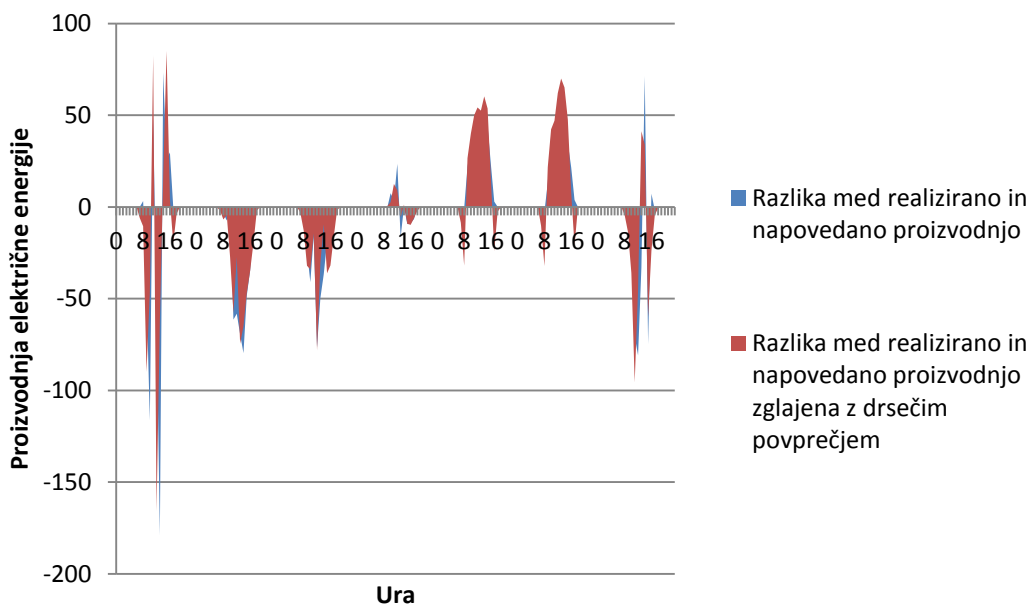
Slika 35: Napoved proizvodnje električne energije za poletno obdobje



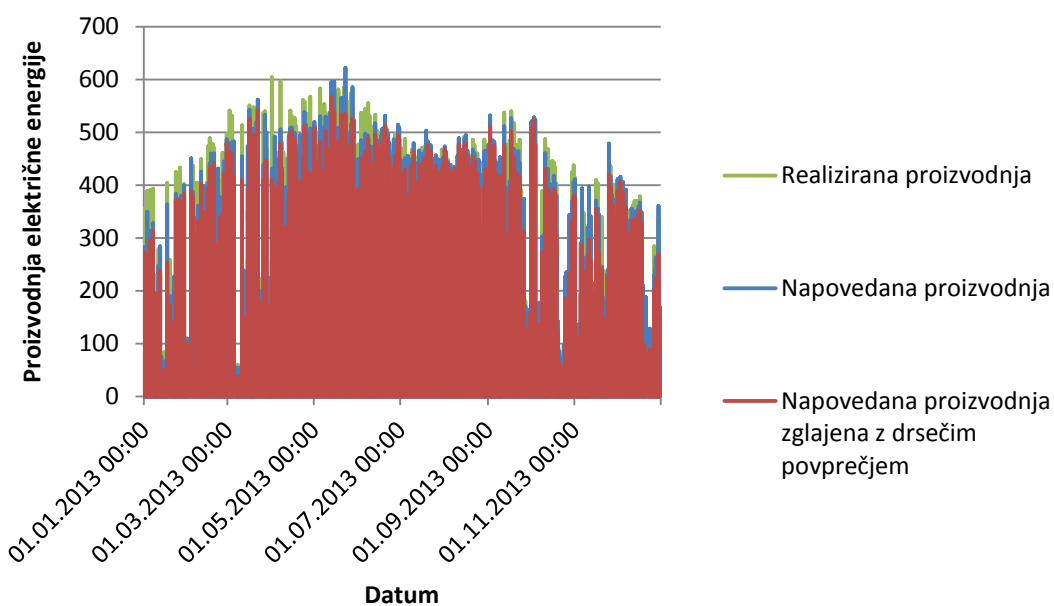
Slika 36: Odstopanje napovedi proizvodnje od realizirane proizvodnje za poletno obdobje



Slika 37: Napoved proizvodnje električne energije za jesensko obdobje



Slika 38: Odstopanje napovedi proizvodnje od realizirane proizvodnje za jesensko obdobje



Slika 39: Simulacija napovedi proizvodnje električne energije za leto 2013

Na sliki 39 je predstavljena simulacija celoletne napovedi proizvodnje električne energije iz sončnih elektrarn za leto 2013. Korelacijski koeficient med napovedano in realizirano proizvodnjo je 0,98172966, medtem ko je korelacijski koeficient med napovedano proizvodnjo zglajeno z drsečim povprečjem in realizirano proizvodnjo 0,97970703. Ponovno se je izkazala minimalna razlika korelacijskih koeficientov med obema metodama.

5.4 Statistične metode za merjenje napak

V tem poglavju smo preučili prednosti in slabosti določenih statističnih metod za merjenje napak in obravnavali njihovo ustreznost v okviru različnih okoliščin. Statistika za merjenje napak igra ključno vlogo pri natančnosti napovedi za sledenje, spremljanje izjeme in primerjalno analizo svoje napovedi procesa. Razlaga teh statističnih podatkov je lahko težavna, za apliciranje spodaj opisanih statističnih metod je potrebno biti pozoren na podatke z majhnimi vrednostmi in zajeti velik obseg vzorcev.

5.4.1 MAPE – Povprečna absolutna odstotna napaka

MAPE (angl. Mean Absolute Percent Error) meri velikost napake v odstotkih. To se izračuna kot povprečje odstotnih napak z enačbo (19).

$$MAPE = \left(\frac{1}{n} \sum \frac{|Realizacija - Napoved|}{|Realizacija|} \right) \cdot 100 \quad (19)$$

Številne organizacije se osredotočajo na MAPE predvsem pri ocenjevanju napovedi natančnosti. Večini ljudi je razmišljanje in predstava v odstotkih domača, zato je izračune z metodo MAPE enostavno razložiti. Informacije, izražene v odstotkih, je tudi lažje razumeti v primerjavi s podatki, izraženimi v številkah (Forecasting, 2014).

Metoda MAPE je občutljiva na obseg vrednosti podatkov, zato je ni primerno uporabljati pri delu z majhnimi vrednostmi podatkov. Paziti je potrebno na vrednost realizacije, ki je v imenovalcu enačbe. Izračun MAPE ni definiran, kadar je vrednost realizacije enaka nič. Poleg tega, če vrednost realizacije ni enaka nič, vendar se ničli približuje, bo vrednost izračuna MAPE ekstremnih vrednosti. Občutljivost obsega vrednosti povzroči, da je MAPE za merjenje napak z majhnimi vrednostmi skoraj neuporaben (Forecasting, 2014).

Tabela 2 prikazuje vrednosti MAPE po mesecih za simulirano napoved za leto 2013.

MAPE za simulirano napoved proizvodnje za leto 2013 je 20,35982 %. Odstotek je sprejemljiv in predstavlja povprečno absolutno odstotno napako.

Tabela 2: Vrednosti MAPE po mesecih

Mesec	MAPE (%)
Januar	22,25234577
Februar	19,68555947
Marec	24,0151082
April	13,49512939
Maj	18,28492069
Junij	15,71619992
Julij	11,52162701
Avgust	12,00263656
September	18,05641253
Oktober	21,90556793
November	30,25853545
December	36,9323711

5.4.2 MAD – Povprečni absolutni odklon

MAD (angl. Mean Absolute Deviation) meri velikost napake v enotah. To se izračuna kot povprečje napak z enačbo (20).

$$MAD = \frac{1}{n} \sum |Realizacija - Napoved| \quad (20)$$

Statistična metoda MAD se uporablja pri analizi napake za posamezen element. Ob združitvi izračunov MAD moramo biti previdni pri velikih vrednostih izračunov, ki dominirajo rezultate.

MAPE in MAD sta daleč najpogosteje uporabljeni statistični metodi merjenja napak. Poleg naštetih obstaja še kup alternativnih statističnih metod merjenja napak, od katerih so mnoge zgolj variacije metod MAPE in MAD, in sicer MAD/povprečno razmerje (MAD/angl. Mean Ration), GMRAE (angl. Geometric Mean Relative Absolute Error) – geometrična povprečna relativna absolutna napaka, SMAPE (angl. Symmetric Mean Absolute Percentage Error) ali simetrična povprečna absolutna odstotna napaka (Forecasting, 2014).

Tabela 3 prikazuje vrednosti MAD po mesecih za simulirano napoved za leto 2013.

Izračun MAD za simulirano napoved proizvodnje za leto 2013 je 11,95279 % in predstavlja povprečni absolutni odklon.

Tabela 3: Vrednosti MAD po mesecih

Mesec	MAD (%)
Januar	10,08228278
Februar	11,41950604
Marec	12,02153271
April	17,23988519
Maj	14,90241352
Junij	12,50051187
Julij	10,56776759
Avgust	8,512968607
September	17,406075
Oktober	11,33265231
November	10,40207067
December	7,308313782

6 ZAKLJUČEK

Sončne elektrarne predstavljajo majhen, vendar vseeno nezanemarljiv delež proizvodnje in odkupa električne energije. Napovedovanje proizvodnje električne energije iz sončnih elektrarn ima še veliko širši pomen. Rast deleža energije v omrežju, proizvedene iz obnovljivih virov energije je občutna, kar predstavlja tudi ključni cilj pobud za pametna omrežja. Ključni cilj prizadevanj za pametna omrežja je bistveno povečati uveljavitev okolju prijaznih obnovljivih virov energije, kot so sončna in vetrna. Eden izmed izzivov z integracijo obnovljivih virov energije v omrežje je ta, da je njihova proizvodnja električne energije s prekinitvami in neobvladljiva, spreminja se glede na vremenske razmere in razmere na določenem mestu. Napovedovanje proizvodnje električne energije iz obnovljivih virov je zatoj pomembno, saj mora omrežje nenehno spremljati in vzpostavljati ravnovesje za zadovoljitev povpraševanja, tako kot se proizvodnja razlikuje. Medtem ko je ročno razvijanje visoko razvitih modelov za napovedovanje lahko izvedljivo za velike sončne proizvodne naprave, je razvoj porazdeljene proizvodnje na milijonih domov po vsem omrežju zahteven problem. Za reševanje problema v tem delu, smo raziskali samodejno ustvarjanje modelov za napovedovanje proizvodnje sončne električne energije iz vremenskih napovedi Agencije Republike Slovenije za okolje. Izpeljane modele iz tega dela se že lahko neposredno uporabi v poslovnih procesih družbe E 3, energetika, ekologija, ekonomija, d.o.o.

Predhodni modeli družbe E 3, d.o.o. za napovedovanje proizvodnje električne energije so temeljili predvsem na neposredni preteklosti, vendar ti modeli ne morejo napovedati spremembe v vremenskih vzorcih vnaprej. Vremenske napovedi Agencije Republike Slovenije za okolje so verodostojne in sposobne zagotoviti morebitna vnaprejšnja opozorila. ARSO ustvarja napovedi iz več visoko razvitih modelov napovedi. Pokazali smo, da je razmerje med vremenskimi spremenljivkami in globalnim sevanjem kompleksno.

Družbi E 3, d.o.o. priporočam uporabo razvitih modelov za napovedovanje proizvodnje električne energije iz sončnih elektrarn in razvoj novih modelov za napovedovanje proizvodnje električne energije iz ostalih obnovljivih virov. Po enaki metodi namreč lahko razvijemo modele za napovedovanje električne energije iz na primer vetrnih elektrarn in hidroelektrarn. Združevanje in širitev modelov bi tako

prispevalo k še natančnejšemu napovedovanju proizvodnje električne energije, kar je vplivni dejavnik odločanja pri nakupu električne energije, enemu izmed glavnih in pomembnejših poslovnih procesov družbe.

Naši rezultati kažejo, da je samodejno tvorjenje natančnih modelov, ki napovedujejo proizvodnjo električne energije iz sončnih elektrarn na podlagi vremenskih napovedi, obetavno področje. Povečana natančnost napovedi proizvodnje električne energije pa je bistvenega pomena za povečanje deleža obnovljivih virov energije v omrežje.

7 LITERATURA

Analemma. Pridobljeno 14. 8. 2014 s svetovnega spleta: <http://en.wikipedia.org/wiki/Analema>

Andrejašic, M. (2007). Fotocelice. Izbrana poglavja iz uporabne fizike. Ljubljana: Fakulteta za matematiko in fiziko, Univerza v Ljubljani.

Bowerman, B. L., O'Connell, R. T., Orris, J. B. (2004). Essentials of Business Statistics. New York: McGraw-Hill.

Day and Night World Map. Pridobljeno 14. 8. 2014 s svetovnega spleta: <http://www.timeanddate.com/worldclock/sunearth.html>

Družbena odgovornost. Pridobljeno 10. 3. 2014 s svetovnega spleta: <http://www.e3.si/e3/e3-predstavitev/e3-druzbena-odgovornost/>

Excel Regression Analysis Output Explained. Pridobljeno 1. 9. 2014 s svetovnega spleta: <http://www.statisticshowto.com/excel-regression-analysis-output-explained/>

Forecasting 101: A Guide to Forecast Error Measurement Statistics and How to Use Them. Pridobljeno 23. 7. 2014 s svetovnega spleta: <http://www.forecastpro.com/Trends/forecasting101August2011.html>

Geografski informacijski sistem. Pridobljeno 18. 4. 2014 s svetovnega spleta: http://www.domplan.si/DOMPLAN_NEW,,urbanizem,geo._info._sistem_gis_.htm

Getting the Best Solar Panel Efficiency and the Factors that Affect it. Pridobljeno 31. 7. 2014 s svetovnega spleta: <http://www.pursolaraz.com/learn-about-solar/what-affects-solar-panel-efficiency-2/>

Interpreting Regression Output. Pridobljeno 1. 9. 2014 s svetovnega spleta: http://dss.princeton.edu/online_help/analysis/interpreting_regression.htm

Kje nas najdete. Pridobljeno 10. 3. 2014 s svetovnega spleta: http://www.elektroprimorska.si/sl-si/o_nas/predstavitev_podjetja/kje_nas_najdete/default.aspx

Košmelj, K. (2007). Uporabna statistika. Ljubljana: Biotehniška fakulteta, Univerza v Ljubljani.

Ličen, D. (2011). Poročilo družbe za leto 2010. Nova Gorica: E 3, energetika, ekologija, ekonomija, d.o.o.

Mekhilef, S., Saidur, R., Kamalisarvestani, M. (2012). Effect of dust, humidity and air velocity on efficiency of photovoltaic cells. V: Renewable & Sustainable Energy Reviews, Volume 16, Issue 5. Philadelphia: Elsevier, str. 2920-2925.

Moving average. Pridobljeno 11. 8. 2014 s svetovnega spleta: http://en.wikipedia.org/wiki/Moving_average

Orlov, M. L. (1996). Multiple linear regression analysis using Microsoft Excel. Corvallis: Chemistry Department, Oregon State University.

Paul McFedries. (2004). Formulas and Functions with Microsoft Excel 2003. Indianapolis: Que.

Pearsonov koeficient korelacije. Pridobljeno 4. 8. 2014 s svetovnega spleta: http://sl.wikipedia.org/wiki/Pearsonov_koeficient_korelacije

Perform a regression analysis. Pridobljeno 25. 7. 2014 s svetovnega spleta: <http://office.microsoft.com/en-us/excel-help/perform-a-regression-analysis-HA001111963.aspx>

Poročilo družbe za leto 2010. (2011). Letno poročilo. Nova Gorica: E 3, energetika, ekologija, ekonomija, d.o.o.

Predstavitev podjetja. (2012). Promocijsko gradivo. Nova Gorica: E 3, energetika, ekologija, ekonomija, d.o.o.

SamsaraLight. Pridobljeno 14. 8. 2014 s svetovnega spleta: http://capsis.cirad.fr/capsis/help_en/samsaralight

Solar panel efficiency. Pridobljeno 13. 8. 2014 s svetovnega spleta: <http://www.renewablegreenenergypower.com/solar-panel-efficiency/>

Solar Path. Pridobljeno 14. 8. 2014 s svetovnega spleta:
http://www.lafenergy.com/ms/PV_system/fig7_sunpath.php

Solar Tracker. Pridobljeno 12. 8. 2014 s svetovnega spleta:
<http://www.reuk.co.uk/Solar-Tracker.htm>

Sovič, B. (2009). Optimizacija oskrbe z obnovljivimi viri energije. Magistrsko delo. (Fakulteta za elektrotehniko, računalništvo in informatiko, Univerza v Mariboru), Maribor: [B. Sovič].

Strateške stalnice. Pridobljeno 10. 3. 2014 s svetovnega spleta:
<http://www.e3.si/e3/e3-predstavitev/e3-strateske-stalnice/>

The Impact of Temperature on Solar Panels. Pridobljeno 31. 7. 2014 s svetovnega spleta: <http://www.thegreenage.co.uk/article/the-impact-of-temperature-on-solar-panels/>

Turk, G. (2011). Verjetnostni račun in statistika. Ljubljana: Fakulteta za gradbeništvo in geodezijo, Univerza v Ljubljani.