

Kratkoročno napovedovanje porabe električne energije po regijah za območje Slovenije

Štefan Kunstelj, Matej Rejc, Miloš Pantoš

Univerza v Ljubljani, Fakulteta za elektrotehniko, Tržaška 25, 1000 Ljubljana, Slovenija
E-pošta: stefan.kunstelj@fe.uni-lj.si, matej.rejc@fe.uni-lj.si, milos.pantos@fe.uni-lj.si

Povzetek. Namen prispevka je predstaviti izboljšani postopek kratkoročnega napovedovanja porabe električne energije z ločevanjem širšega območja napovedi na regije. Z ločitvijo širšega območja na manjše regije lahko pri napovedih točneje zajamemo lokalne geografske, socialne in ekonomske značilnosti. Končna napoved celotnega območja je tako vsota napovedi posameznih regij. Za napoved regij smo v prispevku uporabili regresijski model, ki upošteva pretekli potek porabe električne energije in vremenske podatke. Rezultati napovedi na primeru slovenskega elektroenergetskega sistema za obdobje enega leta kažejo na izboljšavo natančnosti predlaganega postopka, saj se natančnost izboljša za 13 odstotkov, obenem pa z opisano metodo pridobimo informacijo o regijski porabi, kar nam lahko pomaga tudi pri drugih vidikih vodenja sistema, kot je optimalno angažiranje proizvodnje glede na lokalne značilnosti elektroenergetskega sistema.

Ključne besede: napovedovanje električne energije, regijska razčlenitev, slabi podatki, robustna linearna regresija

Regional short-term load forecasting for Slovenia

The paper presents an improved method of short-term load forecasting. Based on regional forecasts, the method forecasts power demand for separate regional areas of Slovenia, i.e. the electric load. For the forecasts to be optimal, it is important to use appropriate, quality-regression models. To get quality results, the data used have to be of good quality, and the previous used input data have to be rechecked to omit any inappropriate ones. Slovenia has a variable terrain and the impact of the weather states rapidly changes, at the distance of only a few kilometers. This is why the area of Slovenia has to be divided into regions where the local impact weather is more pronounced. By accurately forecasting the load, the power system can operate efficiently and reliably. The obtained results indicate that short-term regional forecasting provide better results than classic approach to forecasting where forecasting is made by downscaling the forecasts for a wider area.

1 UVOD

Ker v elektroenergetskih sistemih (EES) ne moremo učinkovito shranjevati električne energije, moramo ohranjati ravnotežje med proizvodnjo in porabo električne moči, s čimer vzdržujemo kakovost frekvence v sistemu. Zato mora biti v EES dovolj proizvodnih zmogljivosti, s čimer ohranjamo to ravnotežje. Ker pri ohranjanju tega ravnotežja večinoma sodelujejo klasične termoelektrarne, morajo te biti v stalni pripravljenosti. S sodobnimi zahtevami po optimizaciji stroškov je treba vnaprej napovedati porabo električne energije, s čimer lahko vnaprej optimalno razporedimo potrebne

proizvodne rezerve. Z uvedbo trga z električno energijo in regulacijskih zahtev potrebujemo natančne kratkoročne napovedi, saj je treba potek porabe vnaprej določiti. Odstopanja od napovedi vodijo k povečanim stroškom v obliki regulatornih kazni in dražje električne energije. Ti stroški so posledica nakupa električne energije iz rezerv sekundarne regulacije, ki ima v ceno energije vključeno tudi ceno hitre odzivnosti povečanja moči.

Posledično natančne napovedi koristijo pri zmanjševanju stroškov sistemskih operaterjev in drugih bilančnih skupin, kar se prav tako odraža v nižjih cenah električne energije za odjemalce in gospodarstvo.

V tem prispevku podamo metodo kratkoročnega napovedovanja porabe električne energije z ločevanjem območja napovedi na regije. Cilj ločevanja širšega območja na manjše regije je izboljšanje natančnosti napovedi, saj lahko pri napovedih z večjo točnostjo zajamemo lokalne geografske, socialne in ekonomske značilnosti [1]. Po postopku napovedi posameznih regij združimo te napovedi v celoto, s čimer lahko izboljšamo natančnost skupne napovedi, saj posredno zajamemo raznolikost terena območja in lokalnih vremenskih vplivov.

Utemeljitev za ločitev širšega območja na manjše regije je podana v [1]–[4], kjer so raziskovalci prikazali vpliv raznolikosti vremena, določenega na različnih lokacijah, na porabo, variacijo vremena med lokacijami, ter na primeru prikazali prednosti regijskega modela napovedi v primerjavi z enotnim. Ker ima Slovenija

izjemno raznolik relief, raznolike vremenske razmere ter vsebuje lokacijsko različne posebnosti v EES [5], smo se odločili za regijsko napovedovanje porabe električne energije v Sloveniji. Pri tem govorimo o porabi električne energije z vidika razdelilnih transformatorskih postaj med prenosnim in distribucijskim omrežjem. V prispevku v pojem porabe električne energije štejemo porabo odjemalcev v distribucijskem omrežju in izgub električne energije v distribucijskem omrežju.

Za napoved porabe električne energije po regijah moramo uporabiti čim ustrežnejšo metodo napovedi, ki poda dobre napovedi za vsako regijo. V literaturi obstajajo različne metode za napovedovanje, kot so metode podobnih dni [6], linearni modeli [7], časovne serije [8], [9], umetna nevronska mreža [11], odločanje na podlagi teorije mehkih množic (angl. fuzzy logic) [12], ekspertni sistemi [13] itd. Vsaka metoda ima svoje prednosti, v prispevku pa smo uporabili robustno linearno regresijo, ki ima to dobro lastnost, da odstrani vpliv vzvodnih točk. To so točke, ki so daleč od regresorskega prostora in potencialno lahko močno vplivajo na oceno regresijskih koeficientov.

V poglavju 2 smo podali teoretično ozadje predlaganega načina za napovedovanje po regijah. V podpoglavju 2.1 smo prikazali razdelitev širšega območja na regije, v podpoglavju 2.2 smo opisali zaznavo slabih vhodnih podatkov. V podpoglavju 2.3 smo podali način določitve modela napovedi ter opisali uporabo metode robustne linearne regresije za učenje modela, v podpoglavju 2.4 pa smo podali opis končnega združevanja regij v širše območje. V poglavju 3 prikažemo rezultate predlagane metode, ki jo primerjamo s klasično metodo za Slovenijo. V zadnjem, poglavju **Error! Reference source not found.**, pa podamo ugotovitve predlaganega načina napovedovanja porabe električne energije.

2 METODA NAPOVEDOVANJA PO REGIJAH

Predlagana metoda za kratkoročno napoved porabe električne energije po regijah je podana na sliki 1. Sestavljena je iz naslednjih podsklopov:

- razporeditev podatkov po regijah,
- zaznavanje slabih podatkov,
- graditev modela napovedi ter kratkoročna napoved porabe po regijah ter
- združevanje napovedi po regijah v celoto.

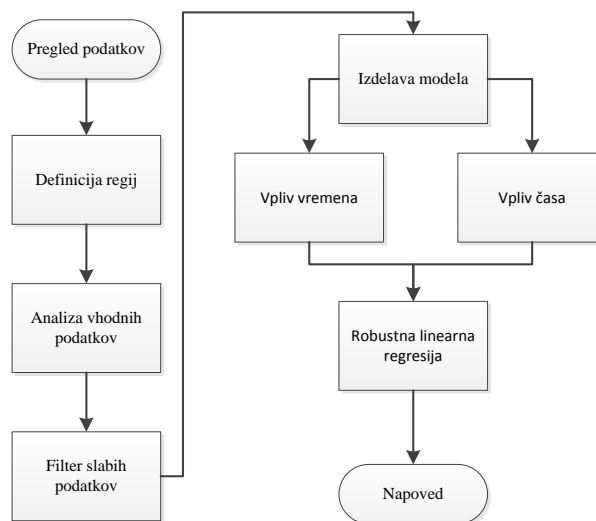
V prvem podsklopu metode razdelimo podatke o porabi električne energije po regijah. Regije širšega območja lahko ločimo na različne načine, bodisi glede na upravne ločitve regij bodisi glede na podnebne značilnosti, demografske značilnosti ipd. V tem članku smo uporabili upravne ločitve regij. Posamezni regiji smo pripisali porabo glede na razpoložljive meritve. Podatki porabe predstavljajo meritve na razdelilnih transformatorskih postajah iz prenosnega v distribucijsko omrežje. Sem štejemo le porabo odjemalcev v distribucijskem omrežju in izgube

električne energije na izvodih posameznih razdelilnih transformatorskih postaj.

V drugem podsklopu moramo te podatke prečistiti, saj v praksi podatki lahko vsebujejo napake. Zato je treba uporabiti algoritem za zaznavo slabih podatkov in te odpraviti. Slabe vrednosti smo določili na podlagi drsečega povprečja in urne variabilnosti podatkov.

V tretjem podsklopu določimo model napovedi in prek robustne linearne regresije napovemo porabo električne energije po regijah. Sam model upošteva vpliv vremena in časovno odvisnost porabe. Robustno linearno regresijo smo uporabili zato, ker je preprosta in ker meritvam, ki so bližje regresorskega prostora, da večjo veljavo, s čimer metoda doseže izjemno dobre rezultate [15].

V četrtem podsklopu napovedi posameznih regij združimo, s čimer dobimo tudi napoved širše regije.



Slika 1: Diagram poteka regijskega napovedovanja


2.1 Razporeditev podatkov po regijah

Regije nam podajo omejitve območja, na katerem združujemo meritve vremena in porabe. Za določitev regij smo se odločili uporabiti upravno razčlenitev, ki jo je podal Statistični urad RS [14]. Ta razčlenitev dobro upošteva geografske značilnosti posameznih regij v Sloveniji, v katerih velja dobra podobnost vremena.

Vsa merilna mesta, ki se lokacijsko nahajajo v regiji smo sešteli, s čimer dobimo skupno porabo regije. Pri določitvi skupnega vremenskega vpliva smo podatke o vremenu utežnostno povprečili. Uteži smo določili tako, da smo vremenskim postajam pripisali najbližja merilna mesta porabe, razmerje te najbližje porabe v primerjavi s skupno porabo regije pa je definiralo utež za vremensko postajo, enačba (1). S tem lokacije, ki imajo večji odjem, več prispevajo v nadomestni diagram vremena.

$$V_r = \sum_{i=1}^n V_i \frac{\bar{P}_i}{\bar{P}_r} \quad (1)$$

V_r označuje nadomestni diagram vremena (npr. temperaturo), V_i označuje vreme na odjemi lokaciji i , \bar{P}_i je povprečje porabe na odjemni lokaciji i in \bar{P}_r je regijsko povprečje porabe.



Slika 2: Upravna razčlenitev Slovenije v regije, [14]

2.2 Zaznavanje slabih podatkov


V praksi se pogosti pripeti, da imamo opravka s podatki, ki imajo slabe in manjkajoče vrednosti. Zato je treba pred izvedbo napovedi preveriti, s kakšnimi podatki oz. kakovostjo podatkov imamo opravka. Nekateri podatki so lahko očitno napačni, lahko manjkajo ipd. Zato je pred napovedovanjem porabe električne energije ključnega pomena, da se odstranijo vse neprimerne vrednosti, saj bi te pri učenju modela povzročale dodatne nenatančnosti napovedi [9], [13]. V prispevku smo uporabili kriterij 99 % intervala zaupanja s predhodno odstranitvijo časovnih trendov v seriji podatkov, saj kriteriji intervala zaupanja niso sami po sebi primerni za nestacionarne časovne vrste, kot je potek porabe. Časovne trende v podatkih odstranimo s pomočjo drsečega okna, kjer v oknu določimo trend drsečega povprečja, enačba (2).

$$D(t) = \frac{1}{2\Delta} \sum_{i=-\Delta}^{t+\Delta} P(t+i) \quad (2)$$

$D(t)$ je drseče povprečje točke t , $P(t+i)$ poraba v točki $t+i$ in Δ širina drsečega okna, ki jo moramo nastaviti na naravni večkratnik števila meritev v okviru dneva, drugače dobimo pristranske vrednosti za drseče povprečje. V prispevku smo uporabili širino štirih tednov.


Po odstranitvi časovnih trendov iz opazovanih podatkov primerjamo drsečo povprečje podatkov s 99-odstotnim intervalom zaupanja. Če podatki drsečega povprečja presegajo meje intervala zaupanja, domnevamo, da so podatki slabi, in jih odstranimo.

Na sliki 3 podamo primer manjkajoče vrednosti v podatkih, torej meritve podajo vrednost 0. Ker ta vrednost sega prek intervala zaupanja, upoštevamo ta podatek kot napačen.



Slika 3: Primer manjkajoče vrednosti in podane meje glede na kriterij

Na sliki 4 vidimo drug primer motnje, kjer je prišlo do napake. Ta je lahko posledica napačnih meritev, napačnega beleženja meritev ali pa je meritev pravilna, vendar je na opazovanem izvodu prišlo do neke kratkotrajne sunkovite spremembe, kot je vklop/izklop večjega bremena, stikalnega manevra ipd. Če teh podatkov ne bi odstranili, bi v učenje modela vnesli matematično nesmiselne nelinearne povezave in povečali negotovost obnašanja modela napovedi.



Slika 4: Primer zabeležene motnje

2.3 Izdelava modela za kratkoročno napoved

Na področju napovedovanja porabe električne energije ni univerzalnega modela, ker se vsak sistem obnaša drugače in ima svoje lastnosti. Pred začetkom napovedovanja porabe je treba pogledati, s kakšnimi podatki imamo opravka ter kako se odjem s časom spreminja. Zato sta potrebni analiza vremenskih podatkov in porabe ter analiza časovnega trenda poteka porabe. Na podlagi teh analiz postavimo model za napovedi.

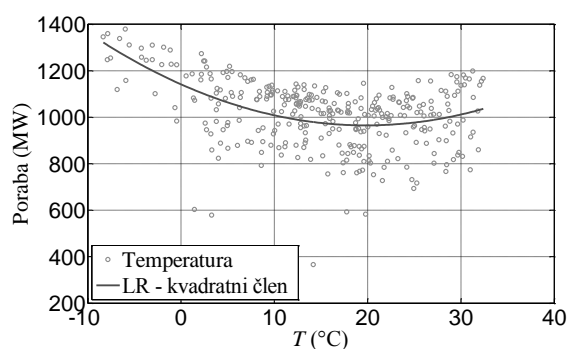
V podpoglavju 2.3.1 podajamo način določanja vremenskih vplivov na porabo in vključitve teh dejavnikov v model, v podpoglavju 2.3.2 pa podajamo način vključitve časovnih povezav v model. V podpoglavju 2.3.3 podamo sam model za napoved, v podpoglavju 2.3.4 pa predstavimo metodo robustne linearne regresije, s katero določimo parametre modela.

2.3.1 Analiza vpliva vremena

Pri določitvi vremenskih vplivnih dejavnikov moramo s statističnimi analizami pogledati, kateri

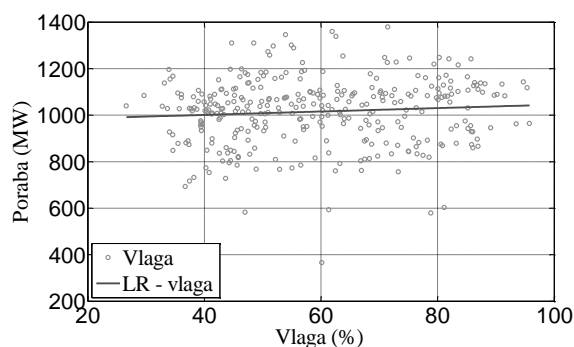
vremenski vplivi vplivajo na porabo električne energije. Ker je to področje dobro raziskano, smo se na podlagi razpoložljivih podatkov (temperatura, vlaga, obsevanost, hitrost vetra) in [10] odločili za morebitno uporabo temperature in relativne vlažnosti kot vplivni dejavnik.

Pri določitvi vpliva vremena na porabo raziskovalci na tem področju uporabljajo predvsem grafične prikaze, iz katerih lahko predvidijo točne matematične povezave. Na sliki 5 podamo primer povezave poraba-temperatura za eno leto za vse delavnike ob 12. uri. Opazimo, da je vpliv temperature kvadraten. Podobno velja tudi za druge ure v dnevu. Zato v regresijskem modelu temperaturo posledično modeliramo s polinomom 2. stopnje. Takšen model nam pojasni 23 % variabilnosti porabe električne energije.



Slika 5: Vpliv temperature na porabo

Na sliki 6 podamo še analizo vlage na porabo. Opazimo šibko povezavo med povečanjem vlage in povečanjem porabe, kljub temu pa je ta povezava dokaj linearna in si z njo lahko pomagamo pri napovedovanju. Za podani primer delavnikov ob 12. uri je tu pojasnjena variabilnost zgolj 0,7-odstotna, kar pomeni, da s pomočjo vlage opišemo izjemno majhen del variabilnosti porabe.




Slika 6: Vpliv vlage na porabo električne energije

2.3.2 Analiza vpliva časa

Podobno kot pri analizi vremenskih vplivov moramo določiti časovni vpliv na porabo. Ker je poraba časovni proces z določeno periodo in sezonami, uporabimo avtokorelacijsko analizo, s katero lahko določimo glavne odloge, s katerimi lahko zajamemo časovno

odvisnost med prihodnostjo in preteklostjo. Odlogi so na urni ravni in nam povedo, kakšna je korelacija med preteklo porabo, ki je zamaknjena za vrednost odloga, in sedanjo porabo.



Slika 7: Avtokorelacija porabe električne energije

Iz slike 7 vidimo, da imajo odlogi največjo vrednost avtokorelacije ravno v zamiku $m \cdot 24h$, kjer je $m = 1, 2, 3, \dots$. Prav tako vidimo, da je avtokorelacija močno pozitivna ravno v razmiku 24 ur. Pozitivna avtokorelacija pomeni, da si dnevi sledijo po podobnosti, npr. dnevno, ki ima veliko porabo, bo sledil dan s prav tako veliko porabo. Ker v praksi pogosto ne poznamo porabe v dnevu, v katerem napovedujemo, takšne informacije ne moremo uporabljati, temveč lahko kvečjemu uporabimo odloge, starejše od enega dneva. Glede na avtokorelacijsko analizo je tako zanimivo uporabiti 48-urni odlog, s katerim zajamemo povezavo med preteklostjo in prihodnostjo.

2.3.3 Zapis modela

Z analizo vhodnih podatkov in njihove povezanosti določimo ustrezeni model napovedi. Ker se napovedi izvajajo dnevno in ker sproti pridobivamo nove podatke o porabi, določamo model vsakič, ko napovedujemo. Za napovedovanje porabe smo vzeli naslednje kriterije:

- vsak dan v tednu ima svoj model,
- opazujemo vsako uro posebej,
- ločimo modele za navadne in posebne dni ter
- vpeljemo modele za prehodno obdobje.

Z vpeljavo teh kriterijev imamo smernice za postavitev regresijskih modelov, ki jih ločimo glede na oddaljenost od posebnih dni. Razlog za uporabo različnih modelov glede na oddaljenost od posebnih dni je njihov vpliv na porabo oz. lahko njihove posebnosti povzročijo statistična odstopanja pri učenjih modela. Posebni dnevi imajo namreč lahko zakasnen vpliv na porabo do enega tedna, zato se zmanjša avtoregresijski del modela.

Za vse dneve, ki so oddaljeni od posebnega dneva več kot sedem dni, uporabimo model, podan z enačbo (3).

$$P_{ij} = \beta_0 + \beta_1 T_{ij} + \beta_2 T_{ij}^2 + \beta_3 \phi_{ij} + \beta_4 P_{i(j-48)} + \beta_5 P_{i(j-72)} + \varepsilon_j \quad (3)$$

P_{ij} je dejanska vrednost odjema za regijo i . Indeks j predstavlja dan, ki ga napovedujemo. Model vsebuje naslednje parametre: temperaturo regije T_{ij} , vlažnost

regije ϕ_{ij} in porabo električne energije v regiji i pred $j-48$ in $j-72$ urami $P_{i(j-48)}$ in $P_{i(j-72)}$. ε_{ij} pomeni ostanek modela.

Za dneve, ki so oddaljeni od posebnih dni za štiri do sedem dni, pa uporabimo model, zapisan z enačbo (4). V tem modelu ne upoštevamo porabe električne energije pred $j-72$ urami.

$$P_{ij} = \beta_0 + \beta_1 T_{ij} + \beta_2 T_{ij}^2 + \beta_3 \phi_{ij} + \beta_4 P_{i(j-48)} + \varepsilon_j. \quad (4)$$

Model, katerega uporabimo od 1 do 4 dni po posebnem dnevu, pa zapišemo z enačbo (5). Tu ne upoštevamo časovne povezave pred $j-48$ in $j-72$ urami.

$$P_{ij} = \beta_0 + \beta_1 T_{ij} + \beta_2 T_{ij}^2 + \beta_3 \phi_{ij} + \varepsilon_j. \quad (5)$$

Za napovedovanje posebnih dni uporabimo model, zapisan z enačbo (3), ki kot vhodne parametre vzame vse posebne dni.

2.3.4 Robustna linearna regresija

Za učenje regresijskih modelov napovedovanja porabe, opisanih v podpoglavju 2.3.3, uporabimo robustno linearno regresijo (RLR) [15], ki uporablja nadgrajeno metodo najmanjših kvadratov. RLR pomeni izboljšavo klasične metode najmanjših kvadratov, ki je občutljiva na pristnost podatkov, ki pomenijo regresijske osamelce ali vzvodne točke. To so točke, ki znatno vplivajo na oceno regresijskih koeficientov. Da izničimo vpliv vzvodnih točk, moramo določiti uteži, ki dajo vzvodnim točkam manjšo veljavo in s tem manjši vpliv na oceno regresijskih koeficientov. Potencialni kandidati za vzvodne točke so ponavadi ekstremne vrednosti.

Regresijske koeficiente za metodo najmanjših kvadratov definiramo z osnovnim modelom linearne regresije:

$$y_i = \beta_0 + \beta_1 x_{1,i} + \dots + \beta_k x_{k,i} + \varepsilon_i. \quad (6)$$

Vrednost y_i je vrednost odvisne spremenljivke, β_k je moč linearnega člana oziroma vpliv člana na vrednost odvisne spremenljivke, $x_{k,i}$ pomeni neodvisno spremenljivko, v tem primeru temperaturo in vlago, in ε_i pomeni ostanek. Regresijske koeficiente v matrični obliki enačbe (6) zapišemo kot:

$$\mathbf{b} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}, \quad (7)$$

kjer je \mathbf{b} vektor ocenjenih regresijskih koeficientov, \mathbf{X} matrika neodvisnih spremenljivk in \mathbf{y} vektor odvisnih spremenljivk. Za izračun regresijskih koeficientov \mathbf{b} metode RLR minimiziramo kriterijsko funkcijo S :

$$S(\mathbf{b}) = \sum_{i=1}^h w_i e_i^2, \quad (8)$$

kjer je w_i utež ostanka, e_i ostanek in h število dni, ki so vneseni v regresijski model.

Za izračun uteži smo uporabili Tukeyevo metodo bisquare:

$$w_{Bi}(e_i) = \begin{cases} \left[1 - \left(\frac{e_i}{k} \right)^2 \right]^2, & |e_i| \leq k \\ 0, & |e_i| > k \end{cases} \quad (9)$$

Faktor k (ang. tuning constant) je definiran kot $k = 4.685\sigma$. Pri tem je $\sigma = MAR / 0.6745$, kjer je MAR mediana absolutnih ostankov. RLR je iteracijski postopek izračuna regresijskih koeficientov.

$$\mathbf{b}^{(t)} = (\mathbf{X}^T \mathbf{W}^{(t-1)} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}^{(t-1)} \mathbf{y} \quad (10)$$

Regresijski vektor koeficientov \mathbf{b} se izračuna s pomočjo matrike vhodnih spremenljivk \mathbf{X} in uteži.

$$\mathbf{W}^{(t-1)} = \text{diag} [w_i^{t-1}], \quad (11)$$

kjer nam $\mathbf{W}^{(t-1)}$ pomeni matriko uteži.

Prednost metode RLR je v tem, da točke, ki so bolj oddaljene od regresorskega prostora, manj vplivajo na oceno koeficientov \mathbf{b} kot pa točke, ki so bližje regresorskega prostora. S tem ko vpeljemo metodo RLR, se nam čas izračuna podaljša, saj je to iteracijska metoda, vendar dobimo bolj robustne ocene koeficientov. Izračun se ustavi, ko dosežemo minimum kriterijske funkcije $S(\mathbf{b})$. Zaustavitveni pogoj za izračun koeficientov je naslednji:

$$|S(\mathbf{b}^{(t)}) - S(\mathbf{b}^{(t-1)})| < \delta, \quad (12)$$

kjer je $S(\mathbf{b}^{(t)})$ vrednost kriterijske funkcije v iteraciji t , $S(\mathbf{b}^{(t-1)})$ je vrednost kriterijske funkcije v iteraciji $t-1$, δ pa je vnaprej definirana vrednost zaustavitvenega pogoja.

2.4 Združevanje napovedi

Da dobimo končno napoved širšega območja, združimo napovedi regij. Skupno napoved izračunamo takole:

$$\hat{P}_s(t) = \sum_{r=1}^n \hat{P}_r(t) \quad (13)$$

Vrednost $\hat{P}_s(t)$ pomeni skupno napoved širšega območja v času t , $\hat{P}_r(t)$ pomeni napoved posamezne regije in n število regij.

3 REZULTATI


Regijsko napovedovanje smo preizkusili za slovenski EES, kjer smo opazovali porabo, zabeleženo na razdelilnih transformatorskih postajah med prenosnim in distribucijskim omrežjem. S tem smo upoštevali porabo električne energije na distribucijskih omrežjih ter izgube, prisotne na izvodih razdelilnih transformatorskih postaj. Na voljo smo imeli podatke za eno leto. Za določitev regij smo uporabili upravno razčlenitev, ki jo določa Statistični urad RS. Ta razčlenitev vsebuje 12 regij. Napovedovali smo regijsko porabo za november 2012, združene napovedi pa primerjali s klasično napovedjo za širše območje. Klasična napoved je enkratna napoved agregirane porabe za celotno državo. Ker lahko regijske napovedi pridobimo prek napovedi širšega območja in uporabe razmerij med porabo v regiji in širšim območjem, smo prav tako primerjali rezultate s klasičnim načinom napovedi regij in v prispevku predlaganim načinom. Klasično napoved regij podamo z enačbo (14).

$$\hat{P}_r(t) = \hat{P}(t)_{cel} \frac{\bar{P}_r}{\bar{P}_{cel}} \quad (14)$$

Vrednost $\hat{P}_r(t)$ pomeni napoved regije v času t , $\hat{P}(t)_{cel}$ je napovedana vrednost porabe celotnega območja v času t , \bar{P}_r je povprečna poraba regije in \bar{P}_{cel} je povprečna poraba celotnega območja.

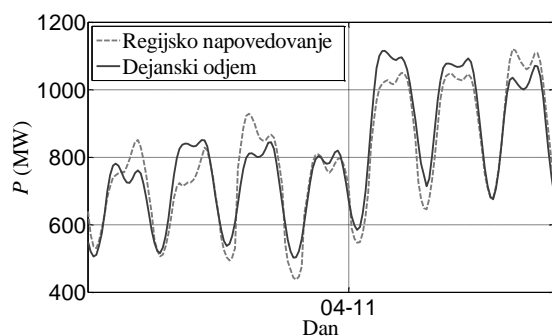
Za analizo natančnosti napovedi smo uporabili kazalnik povprečne absolutne odstotne napake (MAPE).

Na sliki 8 podamo napovedi porabe za november leta 2012. Opazimo, da so odstopanja napovedi v začetku meseca večja, medtem ko na koncu meseca teh odstopanj ni. Razlog je vpliv praznika v časovni bližini začetka meseca, ta pa vpliva na porabo v časovno bližnjih dneh. Za ta mesec je MAPE napoved 2,784 %, standardni odklon napovedi pa 32,96 MW.



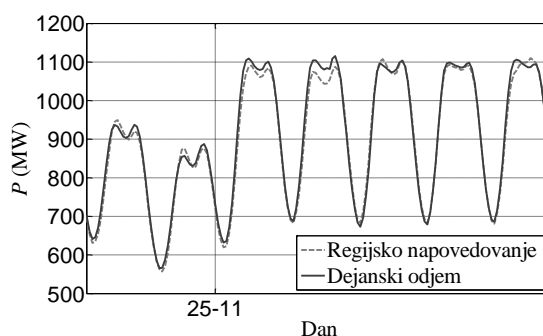
Slika 8: Napoved porabe električne energije za november 2012

Na sliki 9 podamo le napoved porabe za prvi teden novembra. Za prvi teden v mesecu, kjer imamo v bližini dva praznika, MAPE doseže vrednost 6,33 odstotka.



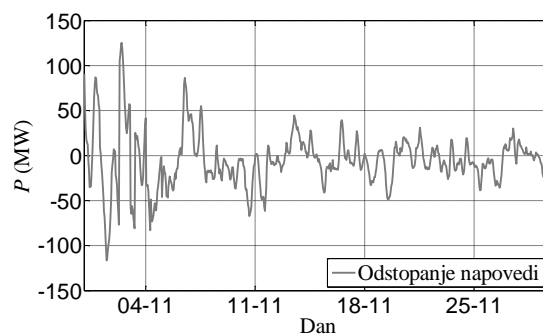
Slika 9: Napoved porabe električne energije v začetku novembra 2012

Na sliki 10 prikažemo le zadnji teden v novembru. Opazimo dobro prilaganje napovedane porabe dejanski porabi za obdobje zadnjega tedna v novembru. V tem obdobju nimamo opravka z nobeno motnjo ali s praznikom, zato so temu primerno kakovostni rezultati. MAPE za ta teden je 1.42 odstotka.



Slika 10: Napoved porabe električne energije za zadnje dni novembra 2012

Na sliki 11 za november prikažemo odstopanje napovedi od dejanske porabe v MW. Na sliki vidimo povečana odstopanja na začetku meseca, ta odstopanja pa se z oddaljenostjo od praznikov zmanjšujejo. Na koncu meseca napaka ne preseže 50 MW, kar pomeni 5-odstotno natančnost.



Slika 11: Odstopanje napovedane vrednosti od dejanske porabe električne energije

Tabela 1 prikazuje analizo natančnosti regijskih napovedi za opazovani mesec november. Te napovedi primerjamo s klasično metodo napovedi širšega območja. Vidimo, da je razlika med metodo regijskega napovedovanja in klasično metodo okvirno 0,37 % v prid regijske metode napovedovanja. Za napoved celotnega območja predlagana metoda poda napovedi z natančnostjo 2,78 %, klasična metoda pa 3,15 %. Regijsko napovedovanje izboljša klasično metodo napovedovanja za 13 %.

Če bi napovedovali regijsko porabo z napovedjo širše regije in razmerij med porabo v regiji in širšem območju, bi prav tako imeli slabšo natančnost napovedi regij proti predlagani metodi v članku.

Tabela 1: Rezultati napovedi RLR regijske in klasične metode

Metoda	Regijska MAPE(%)	Klasična MAPE(%)
1	5,187	7,322
2	3,626	6,054
3	4,345	5,635
4	3,929	7,385
5	3,727	4,030
6	4,995	6,784
7	5,797	10,181
8	3,391	13,008
9	5,682	4,713
10	5,598	7,576
11	2,196	6,579
12	11,122	11,020
Skupna napoved	2,784	3,153

4 SKLEP

Področje napovedovanja porabe električne energije je ključno za ekonomično obratovanje EES. Z natančnimi kratkoročnimi napovedmi porabe električne energije lahko zmanjšamo nepotrebne stroške obratovanja sistema zaradi dragih izravnjav odstopanj med porabo in proizvodnjo električne energije.

Ker napovedi širšega območja ne upoštevajo določenih lokalnih geografskih, vremenskih, socialnih in ekonomskih značilnosti, smo v prispevku podali metodo napovedovanja porabe po regijah. Cilj ločevanja širšega območja na manjše regije je izboljšanje natančnosti napovedi, saj lahko pri napovedih z večjo natančnostjo zajamemo lokalne časovne in vremenske značilnosti regij.

V prispevku smo opisali primer ločitve območja z upoštevanjem upravnih ločitev regij, način zaznave slabih podatkov in izdelavo modela za napoved. Pri tem smo pogledali, kako je poraba električne energije odvisna od vremenskih vplivov in časa.

Metodo smo preizkusili na primeru Slovenije. Rezultati potrjujejo uporabnost predlagane metode, saj nam regijsko napovedovanje poda boljše napoved kot napovedovanje širšega območja. Zaradi pomanjkanja vhodnih podatkov oz. omejenosti na eno leto smo lahko metodo testirali le na enem mesecu, metodo pa bomo s pridobitvijo novih podatkov v prihodnosti testirali tudi za daljše obdobje. Dodana prednost napovedovanja po regijah je tudi pridobitev informacij o obnašanju manjših območij v državi. Ta informacija lahko dodatno pomaga pri vodenju EES, angažiranju proizvodnih enot ipd.

LITERATURA

- [1] Shuangyue Liu; Lina Chen; Juan Wang; Dan Wang; Fei Jiang, "Regional forecast of deep seam mining floor water-bursting based on fuzzy cluster analysis and fuzzy pattern recognition," Conference Anthology, IEEE, vol., no., pp. 1,4, 1–8 Jan. 2013.
- [2] C. J. Ziser, Z. Y. Dong, and T. Saha, "Investigation of weather dependency and load diversity on queensland electricity demand,"

- in Proc. Australasian Univ. Power Eng. Conf., Sep. 25–28, 2005, pp. 457–462.
- [3] Shu Fan; Methaprayoon, K.; Wei-Jen Lee, "Multiregion Load Forecasting for System With Large Geographical Area," Industry Applications, IEEE Transactions on, vol. 45, no. 4, pp. 1452, 1459, July–aug. 2009.
- [4] Shu Fan; Yuan-Kang Wu; Wei-Jen Lee; Ching-Yin Lee, "Comparative study on load forecasting technologies for different geographical distributed loads," Power and Energy Society General Meeting, 2011 IEEE, vol., no., pp.1,8, 24–29 July 2011.
- [5] Jurij Klančnik, Matej Rejc, Miloš Pantoš; »Napoved prenosnih izgub v elektroenergetskem sistemu na podlagi vplivnih distribucijskih faktorjev«, Elektrotehniški vestnik 76(1-2): 51–56, 2009.
- [6] Jing Feng, "A new method for ionospheric short-term forecast using similar-day modeling," Antennas, Propagation & EM Theory (ISAPE), 2012 10th International Symposium on, vol., no., pp.472,474, 22–26 Oct. 2012.
- [7] Yi Guo, Mark Berman, Junbin Gao; "Group subset selection for linear regression Original", Computational Statistics & Data Analysis, Volume 75, July 2014, Pages 39–52.
- [8] Cho, M. Y.; Hwang, J. C.; Chen, C-S, "Customer short term load forecasting by using ARIMA transfer function model," Energy Management and Power Delivery, 1995. Proceedings of EMPD '95., 1995 International Conference on, vol.1, no., pp. 317, 322 vol.1, 21–23 Nov. 1995.
- [9] Jingfei Yang, »Power System Short-term Load Forecasting«, doktorska disertacija, Darmstadt: Technischen Universität Darmstadt, Elektrotechnik und Informationstechnik, 2005.
- [10] Wang Feng; Yu Er Keng; Liu Yong Qi; Liu Jun; Yan Chen Shan, "Short-term load forecasting based on weather information," Power System Technology, 1998. Proceedings. POWERCON '98. 1998 International Conference on, vol.1, no., pp. 572, 575 vol. 1, 18–21 Aug. 1998.
- [11] Zhang Jinhui; Deng Jiajia, "Application of SVM Based on Rough Sets to Short-term Load Forecasting," Intelligent Information Technology Application, 2009. IITA 2009. Third International Symposium on, vol. 3, no., pp. 572, 575, 21–22 Nov. 2009.
- [12] Jarndal, A., "Load forecasting for power system planning using a genetic-fuzzy-neural networks approach," GCC Conference and Exhibition (GCC), 2013 7th IEEE, vol., no., pp. 44, 48, 17–20 Nov. 2013.
- [13] Kratkoročna napoved prenosnih izgub v elektroenergetskem sistemu : doktorska disertacija / Matej Rejc. - Ljubljana : [M. Rejc], 2012. – XXIV.
- [14] SURS [Online], <http://www.stat.si/TematskaKartografija/ExtraLayer.aspx?id=4229> [Dostopano: 25.01.2014].
- [15] Jhon Fox, »Robust Regression«, Januar 2002, [Online] <http://cran.r-project.org/doc/contrib/Fox-Companion/appendix-robust-regression.pdf> [Dostopano: 19.3.2014].

Štefan Kunstelj je magistriral leta 2014 (2. bolonjska stopnja) na Fakulteti za elektrotehniko Univerze v Ljubljani. Trenutno je zaposlen kot raziskovalec v Laboratoriju za elektroenergetske sisteme na Fakulteti za elektrotehniko v Ljubljani.

Matej Rejc je diplomiral leta 2007 in doktoriral leta 2013 na Fakulteti za elektrotehniko Univerze v Ljubljani. Trenutno je zaposlen kot asistent v Laboratoriju za elektroenergetske sisteme na Fakulteti za elektrotehniko v Ljubljani.

Miloš Pantoš je diplomiral leta 2001 in doktoriral leta 2005 na Fakulteti za elektrotehniko Univerze v Ljubljani. Trenutno je zaposlen kot izredni profesor in vodja Laboratorija za elektroenergetske sisteme na Fakulteti za elektrotehniko v Ljubljani.