

Poboljšanje predikcije proizvodnje vetroelektrana u Južnom Banatu kombinovanjem pojedinačnih prognoza pomoću modela veštačke inteligencije

Improving the Prediction of Wind Farm Production in South Banat by Combining Individual Forecasts Using an Artificial Intelligence Model

Milica Koprivica*, Željko Đurišić**

* Elektromreža Srbije, Beograd, Srbija

** Elektrotehnički fakultet, Beograd, Srbija

Rezime - Predikcija proizvodnje vetroelektrana za dan unapred je od ključnog značaja za optimalno angažovanje agregata i minimizaciju troškova balansiranja snaga u elektroenergetskom sistemu. U regionu Južnog Banata je izgrađeno nekoliko vetroelektrana koje koriste različite modele za predikciju proizvodnje. Osnovna ideja u ovom radu je da se, primenom modela veštačke inteligencije, kombinuju predikcije proizvodnje svake od vetroelektrana sa predikcijama proizvodnje ostalih vetroelektrana u regionu. Ovakav pristup ima fizičko opravdanje s obzirom da se sve vetroelektrane nalaze u regionu sa istom klimatologijom vetra.

S obzirom da je za planiranje balansnih kapaciteta od interesa ukupna greška u proceni proizvodnje za dan unapred, u ovom radu je analizirana mogućnost minimizacije kumulativne greške kroz primenu algoritama veštačke inteligencije koji kombinuju prognoze pojedinačnih modela vetroelektrana i na taj način vrše korekciju u proceni zbirne proizvodnje svih vetroelektrana u ovom regionu. Obuka modela neuralne mreže je vršena na osnovu prognoza pojedinačnih vetroelektrana za dan unapred i ostvarenja. Za obuku mreža su korišćeni jednogodišnji setovi prognoziranih i ostvarenih proizvodnja vetroelektrana koje su bile u pogonu u 2020. godini. Razvijeni model predikcije kumulativne proizvodnje vetroelektrana u Južnom Banatu omogućava operatoru prenosnog sistema da vrši naknadnu obradu pojedinačnih predikcija proizvodnje vetroelektrana u cilju smanjenja ukupne greške u proceni kumulativne proizvodnje.

Ključne reči - vetroelektrane, predikcija proizvodnje, veštačka inteligencija

Abstract - The prediction of day-ahead wind farm production is crucial for optimal unit engagement and minimizing power balancing costs in the power system. Several wind farms which use different models to predict the production have been built in the South Banat region. The basic idea in this paper is to combine the production predictions of each of the wind farms with the production predictions of other wind farms in the region using the artificial intelligence model. This approach has a

physical justification given that all wind farms are located in a region with the same wind climatology.

Since the total error in estimating production for the day ahead is of interest for planning balancing capacities, this paper analyses the possibility of minimizing cumulative error through the application of artificial intelligence algorithms. The algorithms combine forecasts of individual wind farm models and thus make corrections in estimating the total production of wind farms in this region. The training of the neural network model was performed on the basis of forecasts of individual wind farms for the day ahead and performance. One-year sets of forecasted and realized wind farm productions that were in operation in 2020 were used to train the networks. The developed model of prediction of cumulative wind farm production in South Banat enables the transmission system operator to perform subsequent processing of individual predictions of wind farm production in order to reduce the total error in the assessment of cumulative production.

Index Terms - wind farms, production prediction, artificial intelligence


I UVOD

Stalan i rapidan razvoj vetroenergetike uočen je poslednjih decenija. Energija vetra, kao čist i obnovljiv oblik energije, igra bitnu ulogu u ublažavanju klimatskih promena. Prema direktivi Evropske asocijacije operatora prenosnih sistema (eng. *ENTSO-e – European Network of Transmission System Operators for electricity*) cilj za 2020. godinu je bio 20% učešća obnovljivih izvora energije u ukupnoj proizvodnji. Ciljevi će se iz godine u godinu povećavati, kako bi se smanjio negativan uticaj efekta staklene bašte na okolinu. Uskoro se očekuje i naplata i ograničavanje proizvodnje ugljen-dioksida - CO₂, a samim tim će se javiti potreba za prelaskom sa fosilnih goriva na čistu energiju.

Pored prednosti koje vetar ima kao čist i besplatan energent, snaga vetra ima i mane - nekontrolabilnost i intermitentnost. Sa

velikim izazovima se suočavaju operatori prenosnih sistema. Jedan od njih je predikcija proizvodnje iz varijabilnih obnovljivih izvora energije.

Na prenosnu mrežu Republike Srbije, do danas, su priključene četiri vetroelektrane instalisane snage oko 374 MW Osnovni podaci o vetroelektranama nalaze se u Tabeli 1.



Slika 1. Raspored vetroelektrana u Južnom Banatu

Tabela 1. Osnovni podaci o vetroelektranama

Vetroelektrana	Pi [MW]	Broj VT	Model	Visina stuba [m]
VE Čibuk 1	158,46	57	GE2.75-120	110
VE Kovačica	104,5	38	GE2.75-120	110
VE Alibunar	42	21	Senvion MM100	100
VE Košava	69	20	Vestas V126 – 3.45	117

Elektromreža Srbije, koja je operator prenosnog sistema, zahteva od proizvođača da dostavljaju prognoziranu proizvodnju za dan unapred sa satnom rezolucijom, kao i replan prognoze proizvodnje tri puta dnevno (unutardnevna prognoza).

Pored prognoza proizvodnje vetroelektrana, Elektromreža Srbije je nabavila i uslugu prognoze proizvodnje od danske kompanije ENFOR.

ENFOR dostavlja prognozu proizvodnje za svaku vetroelektranu pojedinačno. Uočena je veća korelacija među prognozama ENFOR-a, nego u slučaju prognoza koje su dostavljene od strane vetroelektrana. Razlog je algoritam koji se koristi pri prognoziranju. Dok ENFOR koristi isti algoritam, vetroelektrane koriste četiri različita algoritma.

U ovom radu će se iskoristiti upravo različitost algoritama koje koriste vetroelektrane kako bi se, primenom neuralnih mreža, izvršila njihova optimalna kombinacija, čime bi za procenu proizvodnje svake od vetroelektrana koristile i prognoze svih okolnih vetroelektrana. Na ovaj način bi se smanjile greške u proceni proizvodnje svake od vetroelektrana, kao i greška u proceni kumulativne proizvodnje.


II METODOLOGIJA RADA NEURALNE MREŽE

Neuralne mreže su bazirane na veštačkoj inteligenciji i imaju za cilj da odrede izlaz sistema na osnovu ulaza. Koriste se kod stohastičkih sistema, gde je nemoguće odrediti tačnu zavisnost između ulaznih i izlaznih veličina. Dakle, pomoću neuralnih

mreža može da se predviđa izlaz bez poznavanja tačne funkcije prenosa.

Princip rada se zasniva na radu čovekovog nervnog sistema, koji je sposoban da uči i da prethodno iskustvo primenjuje u novim situacijama. Nervni sistem čoveka se sastoji od velikog broja neurona koji vrše obradu i prenos informacija putem hemijskih i električnih signala. Neuroni su povezani sinapsama. Svaki neuron dobija informacije od drugih neurona i bira da li informacije redom prosleđuje sledećim neuronima.

Neuralna mreža je matematički model nervnog sistema koji je u stanju da od ulaznih informacija odredi izlaz koji predstavlja rešenje. Na slici 2 je prikazan matematički model neurona neuralne mreže.



Slika 2. Matematički model neurona neuralne mreže

Na slici 2 se najpre nad ulazom vrši primena linearne transfer funkcije:

$$net = \sum_{i=0}^{n-1} w_i x_i + b \quad (1)$$

gde su:

- w_i - težinski koeficijenti, promenljivi parametri koji su vezani za ulaznu komponentu,
- b - promenljivi parametri (slobodni članovi),
- x_i - ulazi neurona.

Pored linearne, transfer funkcija može biti i kvadratna, polinomijalna i sferična. Rezultat transfer funkcije se koristi kao ulaz u aktivacionu funkciju kako bi se dobio izlaz iz neurona. Neke od najčešće korišćenih aktivacionih funkcija su (slika 3):

- Linearna aktivaciona funkcija

$$f(net) = net \quad (2)$$

- Sigmoid aktivaciona funkcija

$$f(net) = \frac{1}{1 + e^{-net}} \quad (3)$$

- Tangens hiperbolički aktivaciona funkcija

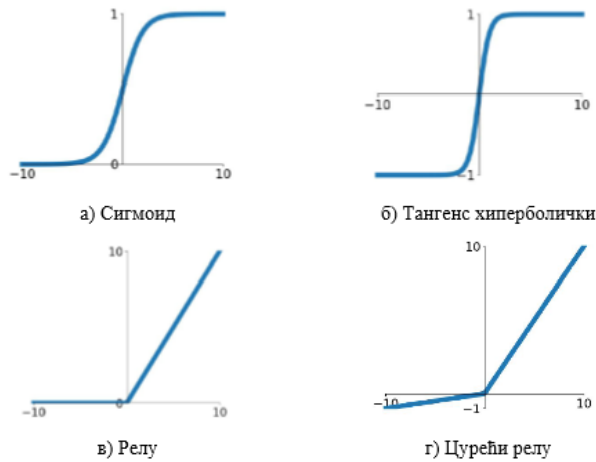
$$f(net) = \tanh(net) \quad (4)$$

- Relu aktivaciona funkcija

$$f(net) = \max(0, net) \quad (5)$$

- Cureća relu aktivaciona funkcija

$$f(net) = \max(0.01net, net) \quad (6)$$




Slika 3. Aktivacione funkcije

Od neurona se formira neuralna mreža, tačnije *feedforward* neuralna mreža. Jedan sloj neurona je skup više neurona sa istim ulazima, ali svaki neuron ima svoje težinske koeficijente. Svaka *feedforward* neuralna mreža se sastoji od ulaznog sloja, skrivenih slojeva i izlaznog sloja.

Izlaz jednog sloja, predstavlja ulaz za naredni sloj neuralne mreže. Ulazni sloj prima podatke koje se dovode na neuralnu mrežu, dok je izlazni sloj poslednji sloj koji formira predikciju na osnovu podataka u ulaznom sloju.

Na slici 4 je primer neuralne mreže sa dva skrivena sloja.



Slika 4. Feedforward neuralna mreža sa dva skrivena sloja

III PRIPREMA ULAZNIH PODATAKA

Ulazni podaci koji su korišćeni pri analizama su sledeći:

- prognoza proizvodnje svake vetroelektrane pojedinačno,
- ostvarena aktivna snaga svake vetroelektrane pojedinačno,
- suma prognoza proizvodnje pojedinačnih vetroelektrana,
- suma ostvarenih aktivnih snaga pojedinačnih vetroelektrana.

Pre formiranja neuralne mreže izvršena je normalizacija ulaznih podataka.

Normalizacija prognoza proizvodnje i ostvarenih aktivnih snaga pojedinačnih vetroelektrana je izvršena sa instalisanim snagama

vetroelektrana koje su umanjene za snagu vetrogeneratora koji su bili van pogona:

$$P_{rasp} = P_{inst} - n_{out} \cdot P_{jed} \quad (7)$$

gde su:

P_{rasp} - raspoloživa instalisana snaga kojom se vrši normalizacija prognoze proizvodnje i ostvarene aktivne snage,
 P_{inst} - instalisana snaga pojedinačnih vetroelektrana,
 P_{jed} - instalisana snaga pojedinačnih vetrogeneratora u posmatranoj vetroelektrani,
 n_{out} - broj vetrogeneratora koji su van pogona u posmatranoj vetroelektrani.

Normalizacija suma prognoza proizvodnje i suma ostvarenih aktivnih snaga pojedinačnih vetroelektrana je izvršena sa sumama instalisanih snaga vetroelektrana koje su umanjene za snagu vetrogeneratora koji su bili van pogona:

$$P_{rasp} = \sum_{i=1}^4 (P_{inst,i} - n_{out,i} \cdot P_{jed,i}) \quad (8)$$

gde su:

P_{rasp} - raspoloživa instalisana snaga kojom se vrši normalizacija suma prognoze proizvodnje i suma ostvarenih aktivnih snaga pojedinačnih vetroelektrana,
 P_{inst} - instalisana snaga pojedinačnih vetroelektrana,
 P_{jed} - instalisana snaga pojedinačnih vetrogeneratora u posmatranoj vetroelektrani,
 n_{out} - broj vetrogeneratora koji su van pogona u posmatranoj vetroelektrani.

Pored smanjenja greške u predikciji proizvodnje svake od vetroelektrana, predloženi model obezbeđuje unapređenje raspoloživosti podataka o prognozi. Ukoliko neka od vetroelektrana, iz nekih razloga, ne ostvari prognozu za neki dan, onda se ta prognoza dobija na osnovu prognoze okolnih vetroelektrana. Dakle za prognozu svake od četiri analizirane vetroelektrane minimalno je potreban set podataka prognoze za jednu vetroelektranu. Naravno kvalitet prognoze će biti veći ako su na raspolaganju svi setovi podataka.

IV MODELI NEURALNIH MREŽA ZA KOMBINOVANU PREDIKCIJU PROIZVODNJE VETROELEKTRANA U JUŽNOM BANATU

U ovom radu su izvršene tri analize u cilju popravke prognoze.

Prva analiza ima za cilj da poboljša prognozu proizvodnje svake vetroelektrane pojedinačno pomoću prognoza ostalih vetroelektrana. Ulazi za neuralnu mrežu su sledeći:


- sat,
- normalizovana vrednost prognoze proizvodnje vetroelektrane čija se prognoza treba poboljšati,
- normalizovane vrednosti prognoze proizvodnje ostalih vetroelektrana u regionu.

Izlaz je normalizovana vrednost ostvarene aktivne snage vetroelektrane čija se prognoza treba poboljšati.

Ova analiza je sprovedena za svaku od četiri vetroelektrane koje su obuhvaćene analizom.

Na slici 5 je dat primer izgleda neuralne mreže za VE Čibuk 1.

Za ostale vetroelektrane se menja redosled ulaza i izlaz – normalizovana vrednost ostvarene aktivne snage, u zavisnosti od vetroelektrane čija se prognoza poboljšava.



Slika 5. Model neuralne mreže na kojoj je rađena analiza za VE Čibuk 1


Druga analiza ima za cilj da poboljša kumulativnu prognozu proizvodnje sve četiri vetroelektrane.

Ulazi za neuralnu mrežu su sledeći:

- sat,
- normalizovane vrednosti prognoze proizvodnje svih vetroelektrana u regionu.

Izlaz je normalizovana vrednost sume ostvarenih aktivnih snaga pojedinačnih vetroelektrana.

Na slici 6 je dat primer izgleda neuralne mreže za drugu analizu.



Slika 6. Model neuralne mreže na kojoj je rađena druga analiza

Treća analiza koristi izlaz iz prve analize, kombinuje ih i upoređuje sa normalizovanom vrednošću ostvarene aktivne snage svih vetroelektrana.

Za razliku od druge analize koja na osnovu prognoziranih vrednosti predviđa kumulativnu snagu proizvodnje svih vetroelektrana, ova analiza koristi rezultate prve analize (aktivna snaga proizvodnje svake vetroelektrane pojedinačno). Rezultati prve analize se kombinuju tako što se sabiraju aktivne snage proizvodnje da bi se dobila kumulativna snaga proizvodnje.

Neuralna mreža koristi arhivu podataka od septembra 2019. godine. Baza se deli na deo za obučavanje (treniranje) neuralne mreže – 70% podataka i deo za testiranje dobijenih rezultata – 30% podataka. Kako su se pri treniranju koristile prognoze proizvodnje, razvijena metodologija, odnosno neuralna mreža

može biti direktno korišćena za unapređenje prognoze proizvodnje vetroelektrana u Južnom Banatu.

V REZULTATI ANALIZA

U ovom poglavlju su prikazani rezultati svake analize pojedinačno, data je struktura neuralne mreže, relativna poboljšanja prognoze proizvodnje i primer poboljšanja prognoze za 20. decembar 2020.

Prva analiza - Poboljšanje prognoze proizvodnje vetroelektrane pomoću prognoza ostalih vetroelektrana

Kao što je opisano u četvrtom poglavlju, prva analiza se sastoji od četiri pojedinačne analize (za svaku vetroelektranu posebno), koje koriste sledeće ulaze:

- sat,
- normalizovana vrednost prognoze proizvodnje vetroelektrane čija se prognoza treba poboljšati,
- normalizovane vrednosti prognoze proizvodnje ostalih vetroelektrana u regionu.

Izlaz je normalizovana vrednost ostvarene aktivne snage vetroelektrane čija prognoza treba da se poboljša. Neuralna mreža ima i dva skrivena sloja sa 120 i 70 neurona (Slika 5).

U Tabeli 1 su prikazane greške u prognozi koje prave vetroelektrane pri prognoziranju i greške koje su rezultat neuralne mreže.

Prosečna greška u postojećoj predikciji proizvodnje vetroelektrana je računata prema sledećoj relaciji:

$$\sigma_{prog_VE} = \frac{\sum |P_{prog_VE} - P_{ostv}|}{n} \cdot 100\% \quad (9)$$

gde su:

P_{prog_VE} - normalizovana vrednost prognoze proizvodnje vetroelektrane čija se prognoza poboljšava, a koju dostavljaju vetroelektrane,

P_{ostv} - normalizovana vrednost ostvarene aktivne snage vetroelektrane čija se prognoza poboljšava,

n - broj sati (odbiraka) nad kojima se vrši analiza.

Prosečna greška se računa za čitavu bazu podataka.

Prosečna greška u poboljšanoj predikciji proizvodnje vetroelektrana, korišćenjem razvijene neuralne mreže, je računata prema sledećoj relaciji:

$$\sigma_{ANN} = \frac{\sum |P_{ANN} - P_{ostv}|}{n} \cdot 100\% \quad (10)$$

gde su:

P_{ANN} - normalizovana vrednost prognoze proizvodnje vetroelektrane čija se prognoza poboljšava koja je rezultat neuralne mreže,

P_{ostv} - normalizovana vrednost ostvarene aktivne snage vetroelektrane čija se prognoza poboljšava,

n - broj sati (odbiraka) nad kojima se vrši analiza.

Relativno poboljšanje prognoze se računa prema formuli:


$$\Delta\sigma = \frac{|\sigma_{ANN} - \sigma_{prog_VE}|}{\sigma_{prog_VE}} \cdot 100\% \quad (11)$$

Tabela 2. Rezultati prve analize - Poboljšanje prognoze proizvodnje vetroelektrane pomoću prognoza ostalih vetroelektrana


Vetroelektrana	σ_{prog_VE} [%]	σ_{ANN} [%]	$\Delta\sigma$ [%]
Čibuk 1	8,97	7,96	11,22
Kovačica	12,50	8,73	30,21
Alibunar	17,31	8,13	53,05
Košava	10,27	7,88	23,32

Neuralna mreža je spustila greške svih vetroelektrana ispod niova greške najbolje prognoze, što je u ovom slučaju prognoza vetroelektrane Čibuk 1. Poboljšanje prognoze se kreće od 11.22% za VE Čibuk, pa do čak 53,05% za VE Alibunar.


Na slikama 7, 8, 9 i 10 dati su grafici ostvarene aktivne snage proizvodnje, prognozirane aktivne snage od strane vetroelektrana i prognozirane aktivne snage koja je rezultat neuralne mreže, za svaku vetroelektranu (primer za dan 20. decembar 2020.).




Slika 7. VE Čibuk 1 – 20. 12. 2020.



Slika 8. VE Kovačica – 20. 12. 2020.



Slika 9. VE Alibunar – 20. 12. 2020.



Slika 10. VE Košava – 20. 12. 2020.

U primeru za 20. 12. 2020. neuralna mreža je izvršila popravku prognoza za VE Čibuk 1, VE Kovačica i VE Alibunar, dok se prosečna dnevna greška za VE Košava povećala. Tabelarni prikaz grešaka je dat u Tabeli 3.

Tabela 3. Rezultati prve analize – Prosečne greške za 20.12.2020.

Vetroelektrana	σ_{prog_VE} [%]	σ_{ANN} [%]	$\Delta\sigma$ [%]
Čibuk 1	7,70	7,10	7,79
Kovačica	17,73	10,03	43,43
Alibunar	16,91	11,71	30,75
Košava	6,90	9,34	-35,36

Druga analiza - Poboljšanje kumulativne prognoze proizvodnje sve četiri vetroelektrane

Druga analiza se sastoji od jedne analize koja koristi sledeće ulaze:

- sat,
- normalizovane vrednosti prognoza proizvodnje sve četiri vetroelektrane.

Izlaz je normalizovana vrednost ostvarene aktivne snage sve četiri vetroelektrane. Neuralna mreža ima i dva skrivena sloja sa 120 i 70 neurona (Slika 6).

U Tabeli 4 su prikazane kumulativne greške u prognozi koje prave vetroelektrane pri prognoziranju postojećim modelima i greške koje su rezultat neuralne mreže.

Tabela 4. Rezultati druge analize - Poboljšanje kumulativne prognoze proizvodnje vetroelektrana

Vetroelektrana	σ_{prog_VE} [%]	σ_{ANN} [%]	$\Delta\sigma$ [%]
Sve vetroelektrane	8,67	7,62	12,10

Greške su računane prema formuli:

$$\sigma_{prog_VE} = \frac{\sum_{n=1}^n |P_{\Sigma prog_VE} - P_{\Sigma ostv}|}{n} \cdot 100\% \quad (12)$$

gde su:

$P_{\Sigma prog_VE}$ - normalizovana vrednost kumulativne prognoze proizvodnje sve četiri vetroelektrane, a koju dostavljaju vetroelektrane,

$P_{\Sigma_{ostv}}$ - normalizovana vrednost kumulativne ostvarene aktivne snage sve četiri vetroelektrane,
 n - broj sati (odbiraka) nad kojima se vrši analiza,

odnosno prema:

$$\sigma_{ANN} = \frac{\sum^n |P_{ANN} - P_{ostv}|}{n} \cdot 100\% \quad (13)$$


gde su:

$P_{\Sigma_{ANN}}$ - normalizovana vrednost kumulativne prognoze proizvodnje sve četiri vetroelektrane, a koja je rezultat neuralne mreže,

$P_{\Sigma_{ostv}}$ - normalizovana vrednost kumulativne ostvarene aktivne snage sve četiri vetroelektrane,
 n - broj sati (odbiraka) nad kojima se vrši analiza.

Relativno poboljšanje prognoze se računa prema formuli (11).

Na slici 11 dati su grafici suma ostvarenih aktivnih snaga proizvodnje, suma prognoziranih aktivnih snaga od strane vetroelektrana i prognozirana aktivna snaga koja je rezultat neuralne mreže za sve vetroelektrane sumarno (primer za dan 20. decembar 2020.).



Slika 11. Sve vetroelektrane – 20. 12. 2020.

U primeru za 20. 12. 2020. neuralna mreža je izvršila popravku prognoze. Tabela prikaz grešaka je dat u Tabeli 5.

Tabela 5. Rezultati druge analize – Prosečne greške za 20.12.2020.

Vetroelektrana	σ_{prog_VE} [%]	σ_{ANN} [%]	$\Delta\sigma$ [%]
Sve VE	8,14	6,20	23,83

Treća analiza - Poboljšanje kumulativne prognoze proizvodnje pomoću rezultata iz prve analize

Treća analiza koristi rezultate pojedinačnih analiza iz prve analize, kombinuje rezultate u cilju poboljšanja kumulativne prognoze proizvodnje. Rezultati prve analize se kombinuju, tako što se sabiraju aktivne snage proizvodnje da bi se dobila kumulativna snaga proizvodnje. Tako dobijena kumulativna snaga proizvodnje se upoređuje sa kumulativnom ostvarenom snagom proizvodnje.

U Tabeli 6 su prikazane kumulativne greške u prognozi koje prave vetroelektrane pri prognoziranju i greške koje su rezultat kombinovanja rezultata prve analize.

Greške su računane prema formuli:

$$\sigma_{prog_VE} = \frac{\sum^n |P_{\Sigma_{prog_VE}} - P_{\Sigma_{ostv}}|}{n} \cdot 100\% \quad (14)$$

gde su:

$P_{\Sigma_{prog_VE}}$ - normalizovana vrednost kumulativne prognoze proizvodnje sve četiri vetroelektrane, a koju dostavljaju vetroelektrane,

$P_{\Sigma_{ostv}}$ - normalizovana vrednost kumulativne ostvarene aktivne snage sve četiri vetroelektrane,
 n - broj sati (odbiraka) nad kojima se vrši analiza,

odnosno prema:

$$\sigma_{ANN} = \frac{\sum^n \left| \left(\sum_{i=1}^4 P_{ANN_{n,i}} \right) - P_{ostv} \right|}{n} \cdot 100\% \quad (15)$$

gde su:


$P_{ANN_{n,i}}$ - normalizovana vrednost prognoze proizvodnje i-te vetroelektrane, a koja je rezultat neuralne mreže,
 P_{ostv} - normalizovana vrednost kumulativne ostvarene aktivne snage sve četiri vetroelektrane,
 n - broj sati (odbiraka) nad kojima se vrši analiza.

Tabela 6. Rezultati treće analize - Poboljšanje kumulativne prognoze proizvodnje vetroelektrana kombinovanjem rezultata iz prve analize

Vetroelektrana	σ_{prog_VE} [%]	σ_{ANN} [%]	$\Delta\sigma$ [%]
Sve vetroelektrane	8,67	6,63	23,53

Relativno poboljšanje prognoze se računa prema formuli (11).

Na slici 12 dati su grafici suma ostvarenih aktivnih snaga proizvodnje, suma prognoziranih aktivnih snaga od strane vetroelektrana i suma prognoziranih aktivnih snaga koje su rezultat neuralne mreže iz prve analize (primer za dan 20. decembar 2020.).



Slika 12. Sve vetroelektrane – 20. 12. 2020.

Tabela 7. Rezultati treće analize – Prosečne greške za 20.12.2020.

Vetroelektrana	$\sigma_{\text{prog. VE}} [\%]$	$\sigma_{\text{ANN}} [\%]$	$\Delta\sigma [\%]$
Sve VE	8,14	7,08	13,02

U primeru za 20. 12. 2020. neuralna mreža je izvršila popravku prognoze. Tabelarni prikaz grešaka je dat u Tabeli 7.

VI ZAKLJUČAK

U regionu Južnog Banata do sada izgrađeno oko 400 MW vetroelektrana, dok je prijavljeno operatoru prenosnog sistema još oko 3000 MW novih projekata vetroelektrana. Region je sa istom klimatologijom vetra pa se mogu očekivati slični rezultati u pogledu vremenskog profila proizvodnje ovih vetroelektrana.

Elektromreža Srbije koja je operator prenosnog sistema Republike Srbije, ugovorom o eksploataciji, traži od klijenata, tj. vlasnika vetroelektrana plan rada za dan unapred. Iste planove, proizvođač je dužan da šalje i svojoj balansno odgovornoj strani.

Kako balansno odgovorna strana plaća naknade u slučaju odstupanja plana i proizvodnje, u interesu je da prognoza bude što tačnija.

Pored toga, Elektromreža Srbije ima zadatak da održava siguran i pouzdan rad prenosnog sistema. Zbog toga je nabavljena i usluga prognoze proizvodnje.

Rezultati ovog rada najviše koriste operatoru prenosnog sistema jer oni imaju sve pojedinačne prognoze, i poboljšanjem prognoza mogu da doprinesu boljem planiranju rada sistema za dan unapred. Pored toga, rezultati su korisni i za balansno odgovornu stranu, u ovom slučaju JP Elektroprivreda Srbije, koja razvijenom neuralnom mrežom može ostvariti kombinovanje prognoza i time bitno smanjiti grešku balansiranja.

Najbolji rezultati se dobijaju u slučaju pojedinačnih prognoza. Kada bi vetroelektrane imale penale usled odstupanja prognoze od ostvarenja, ova analiza bi im donosila značajne finansijske uštede. Najmanju grešku u prognozi ima vetroelektrana Čibuk 1, a njeno relativno poboljšanje, primenom predložene

metodologije, je oko 11%, dok je srednje apsolutno odstupanje smanjeno sa 8,97% na 7,96%. Vetroelektrana Kovačica je imala nešto slabiju prognozu, pa je relativno poboljšanje veće – oko 30%. Vetroelektrana Alibunar ima najveće greške pri prognozi. Relativno poboljšanje je u njenom slučaju najveće i iznosi oko 53%. Relativno poboljšanje prognoze vetroelektrane Košava je oko 23%.

Sve greške su svedene na nivo greške najbolje prognoze - prognoze VE Čibuk 1. Za očekivati je da, u budućnosti, pojavom velikog broja vetroelektrana u istom regionu greška bude na nivou greške najbolje prognoze.

Rezultati neuralne mreže koja je za cilj imala poboljšanje kumulativne prognoze proizvodnje pokazuju relativno poboljšanje prognoze proizvodnje od oko 12% 23,5%, dok je srednje apsolutno odstupanje smanjeno sa 8,67% na 7,62%.

Treća analiza je dala dalje poboljšanje prognoze kumulativne proizvodnje. Postignuto je relativno poboljšanje prognoze proizvodnje od oko 23,5%, dok je srednje apsolutno odstupanje smanjeno sa 8,67% na 6,63%.

LITERATURA

- [1] Kotur, D., Žarković, M. Neural Network Models for Electricity Prices and Loads Short and Long-Term Prediction, in Proc. 4th. *IEEE International Symposium on Environment Friendly Energies and Applications (EFEA)* Belgrade, 2016. <https://doi.org/10.1109/efea.2016.7748787>
- [2] *Directive 2009/28/EC of the European parliament and of the council*, ENTSO-e, 2009. <https://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:L:2009:211:0055:0093:EN:PDF> [pristupljeno 28.03.2021]
- [3] Wasilewski, J., Baczynski, D. Short-term electric energy production forecasting at wind power plants pareto-optimality context, *Renewable and Sustainable Energy Reviews*, Vol. 69, pp 177-187, 2017. <https://doi.org/10.1016/j.rser.2016.11.026>

AUTORI

Milica Koprivica - master inženjer elektrotehnike i računarstva, Elektromreža Srbije, milica.koprivica@ems.rs
dr Željko Đurišić – vanredni profesor, Elektrotehnički fakultet Univerziteta u Beogradu, djurisic@etf.rs