

Unapređenje predikcije snage na izlazu hidroelektrane primenom sezonske segmentacije i SOM-metoda klasterizacije podataka

Stefan Ćubonović

Katedra za elektroenergetiku
Fakultet tehničkih nauka u Čačku
Čačak, Srbija

stefan.cubonovic@ftn.kg.ac.rs, ORCID 0000-0002-0240-5349

Aleksandar Ranković

Katedra za elektroenergetiku
Fakultet tehničkih nauka u Čačku
Čačak, Srbija

aleksandar.rankovic@gmail.com, ORCID 0000-0002-7205-9584

Abstract—Ovaj rad predstavlja nastavak prethodnog istraživanja u primeni veštačkih neuronskih mreža (*Artificial Neural Networks – ANN*) za predikciju snage na izlazu hidroelektrane (HE), korišćenjem dva tipa ANN: veštačke neuronske mreže sa jednosmernim prostiranjem signala (*Feedforward Artificial Neural Networks – FF-ANN*) i rekurentne neuronske mreže (*Recurrent Neural Network – RNN*). U novom pristupu povećan je obim podataka za testiranje modela na celu godinu. Godišnji skup podataka podeljen je u četiri sezonske celine po meteorološkom kriterijumu – proleće, leto, jesen i zima – pri čemu je za svaku sezonu razvijen poseban adaptivni model ANN, sa dodatnom podelom podataka na osnovu dinamike protoka. Kako bi se unapredila preciznost segmentacije radnih režima, u radu je takođe primenjena *Self-Organizing Map (SOM)* neuronska mreža za klasterizaciju podataka, čime je omogućeno bolje prilagodavanje ANN modela različitim uslovima rada. Cilj rada je dodatno unapređenje preciznosti i robusnosti modela kako bi se omogućila bolja prilagodljivost specifičnim hidrološkim i operativnim uslovima svake sezone. Rezultati testiranja pokazuju da sezonski i SOM modeli nadmašuju model treniran na ograničenom periodu, po pitanju preciznosti predviđanja. Na ovaj način doprinosi se poverenju u kreirane modele i otvaraju se mogućnosti za njihovo unapređenje.

Ključne reči — veštačka neuronska mreža, sezonska podela, SOM, hidroelektrana, protok

I. UVOD

Precizna predikcija snage na izlazu hidroelektrane (HE) predstavlja značajan izazov u domenu optimizacije proizvodnje, planiranja balansnih rezervi i smanjenja ekoloških posledica. Savremeni pristupi zasnovani na veštačkoj inteligenciji pokazuju sve veću primenu u ovom kontekstu, pružajući mogućnosti za efikasnije i pouzdanoje modelovanje složenih nelinearnih odnosa između ulaznih veličina i izlazne snage HE. Predikcija snage na izlazu HE još uvek se ne koristi kao zamena za SCADA merenja već kao podrška za unapređenje pouzdanosti i fleksibilnosti sistema. Njena primena uključuje kratkoročno planiranje proizvodnje koje je bitno za automatizovani rad dispečerskih centara gde je neophodno imati očekivane vrednosti za kraći vremenski horizont, radi bolje integracije sa drugim izvorima energije u mreži, detekciju anomalija kroz poređenje očekivanih i merenih vrednosti [1], procenu u uslovima gubitka podataka ili kvarova u komunikacionoj mreži, dugoročno u smislu planiranja politike razvoja sektora energetike itd.

U prethodnom radu [2], analizirana je veštačka neuronska mreža (*Artificial Neural Networks – ANN*) sa jednosmernim prostiranjem signala (*Feedforward Artificial Neural Networks –*

FF-ANN) i rekurentna neuronska mreža (*Recurrent Neural Network – RNN*) u cilju precizne predikcije snage na izlazu HE, pri čemu se trening/test podaci odnose samo na jedan mesec. Rezultati predikcije su pokazali izuzetno podudaranje sa stvarnim vrednostima ali došlo se i do značajnih zaključaka. Utvrđeno je da FF-ANN model postiže veću preciznost pri brzim i naglim promenama protoka vode kroz turbinu, dok se RNN model pokazao efikasnijim pri sporim i postepenim promenama.

Motivisani rezultatima tog istraživanja nastao je ovaj rad koji predstavlja evoluciju prethodnog pristupa kroz uvođenje sezonske segmentacije podataka kao nove strategije za generalizovanje modela. Umesto primene jedinstvenog ANN modela za celu godinu, ovde se polazi od pretpostavke da razlike u hidrološkim uslovima tokom godine zahtevaju odvojeno treniranje modela za proleće, leto, jesen i zimu. Time se povećava mogućnost da se svaka ANN prilagodi specifičnostima sezonskih obrazaca između ulaznih veličina i izlazne snage, čime se poboljšava njena sposobnost generalizacije i preciznosti na test podacima. Dodatno, kako bi se analizirala struktura podataka i identifikovali specifični režimi rada, primenjena je i *Self-Organizing Map (SOM)* neuronska mreža. Ovaj metod klasterizacije omogućava automatsko grupisanje uzoraka na osnovu ulaznih veličina, bez potrebe za unapred definisanim pragovima. Pomoću ova dva pristupa, omogućena je šira i reprezentativnija evaluacija performansi modela u realnim uslovima rada HE.

Rad je koncipiran tako da u I poglavlju pruži uvod u problematiku predikcije snage na izlazu HE i predstavi motivaciju za primenu sezonski prilagođenih i SOM neuronskih mreža. U II poglavlju dat je kratak osvrt na prethodno istraživanje u kojem su upoređeni FF-ANN i RNN modeli, uz dodatnu analizu uticaja brojnosti podataka za testiranje na mesečnu evaluaciju performansi modela pri nepromjenjenom skupu podataka za treniranje. III poglavlje opisuje način podele godišnjih podataka: na četiri sezonska skupa – proleće, leto, jesen i zima, kao i primenom SOM neuronske mreže – uz detalje o pripremi ulaznih i izlaznih podataka. U IV poglavlju prikazan je proces treniranja i evaluacije četiri odvojena adaptivna ANN modela za svaku sezonu. Poređenje se vrši pomoću evaluacionih metrika kao što su MAE, RMSE i R^2 . Na kraju, u zaključnom poglavlju sumirani su rezultati istraživanja i dati glavni doprinosi ovog rada.



II. OPIS PRETHODNOG MODELA

U prethodnom istraživanju modelovane su i analizirane dve arhitekture ANN – FF-ANN i RNN. Obe neuronske mreže se sastoje od tri sloja [3]:

1. Ulagani sloj (Input Layer),
2. Skriveni sloj (Hidden Layer),
3. Izlazni sloj (Output Layer).

Ulagani sloj predstavlja prvi deo mreže i ima ulogu prihvatanja ulaznih podataka. Svaki neuron u ovom sloju predstavlja jednu od ulaznih veličina koje se koriste za obuku ili testiranje mreže. Dakle, broj neurona u ulaznom sloju direktno zavisi od veličina koje se koriste kao ulazni podaci. Ove veličine se mogu dobiti iz različitih izvora, najčešće su to merenja sa senzora na samoj HE ili meteoroloških stanica. Za kreiranje i testiranje ANN-a u radu [2] korišćeno je preko 40000 podataka iz aprila 2023. godine, dok u ovom radu imamo preko 400000 podataka iz cele 2024. godine. Podaci predstavljaju skup sledećih veličina sa vremenskom diskretizacijom od jednog minuta:

1. Statički pad - H_s [m],
2. Protok vode kroz turbinu - Q [m^3/s],
3. Kota gornje vode - H_g [m],
4. Kota donje vode - H_d [m],
5. Temperatura ulazne rashladne vode - θ_{rv} [$^\circ\text{C}$].

Broj slojeva, kao i broj neurona u skrivenim slojevima, predstavlja ključne parametre koji oblikuju tačnost i preciznost mreže [4]. Za odabir optimalnog broja neurona u skrivenom sloju preporučuje se iterativno testiranje koje će rezultirati što tačnijem modelu i sprečavanju nepoželjnog *overfitting* efekta [5].

Izlazni sloj ANN predstavlja krajnji deo mreže i generiše konačne rezultate ili odgovore mreže na osnovu obrade ulaznih veličina. Broj neurona u izlaznom sloju zavisi od tipa problema koji se rešava, u slučaju predikcije snage na izlazu HE dovoljan je jedan izlazni neuron po modelu, a to je izlazna snaga P_{HE} [MW].

U procesu treninga ANN korišćen je MATLAB softverski alat koji koristi podrazumevane algoritme za treniranje mreže: Levenberg-Marquardt algoritam za FF-ANN modele i Scaled Conjugate Gradient algoritam za RNN modele. U funkcije za treniranje neuronskih mreža ugrađeni su mehanizmi za rano zaustavljanje, kojim se obuka prekida kada Mean Squared Error na validacionom skupu počne da raste. Svi proračuni tokom treniranja i testiranja modela vršeni su u MEX (MATLAB Executable) režimu, odnosno proračuni su izvedeni pomoću kompjuiranih funkcija, čime se obezbeđuje brža obrada podataka i značajno skraćuje vreme izvršavanja.

III. NOVE METODOLOGIJE I PROŠIRENI SKUP PODATAKA

A. Sezonska segmentacija podataka po meteorološkom kriterijumu

U cilju unapređenja tačnosti predikcije snage u uslovima izraženih sezonskih varijacija, u ovom radu je izvršena podela godišnjeg skupa podataka na četiri sezonske celine: proleće, leto, jesen i zima. Ova podela omogućava treniranje posebnog ANN

modela za svaku sezonu, pri čemu se svaki model adaptira na karakteristične hidrološke uslove tog perioda godine. Sezonska segmentacija podataka izvršena je prema meteorološkom kriterijumu, pri čemu svaka sezona obuhvata po tri meseca, što omogućava jednostavniju organizaciju, analizu i obradu podataka. Ovakva podela podrazumeva sledeće vremenske okvire:

1. Proleće: 1. mart – 31. maj,
2. Leto: 1. jun – 31. avgust,
3. Jesen: 1. septembar – 30. novembar,
4. Zima: 1. decembar – 28/29. februar.

Pored meteorološkog kriterijuma segmentacija je uradena i na osnovu analize promena u karakteristikama protoka vode kroz turbinu. Time se osigurava da svaki model bude treniran na podacima koji odražavaju specifične operativne uslove u sezoni kojoj pripada. Ovakav pristup se zasniva na matematički definisanom pragu standardne devijacije, koji omogućava jasno kategorisanje podataka. Proces klaster analize [6] započinje definisanjem intervala koji se analizira. Za svaki interval, izračunava se standardna devijacija kako bi se ocenila njegova stabilnost. Standardna devijacija σ za interval sa n merenja definisana je na sledeći način (1):

$$\sigma = \sqrt{\frac{1}{(n-1)} \sum_{i=1}^n (Q_i - \mu)^2}, \quad (1)$$

gde Q_i predstavlja pojedinačne vrednosti protoka u jednom intervalu, a μ je aritmetička sredina tih vrednosti koja se računa primenom (2):

$$\mu = \frac{1}{n} \sum_{i=1}^n Q_i. \quad (2)$$

Prag standardne devijacije θ je unapred određen na osnovu analize podataka i iterativnog testiranja. U ovom radu, prag od 5 m^3/s se pokazao kao optimalan za razlikovanje stabilnih i nestabilnih stanja protoka. Interval T se klasifikuje kao stabilan ako je njegova standardna devijacija σ manja ili jednaka od praga θ i kao nestabilan ako je veća:

$$T = \begin{cases} \text{stabilan, } \sigma \leq \theta \\ \text{nestabilan, } \sigma > \theta \end{cases}. \quad (3)$$

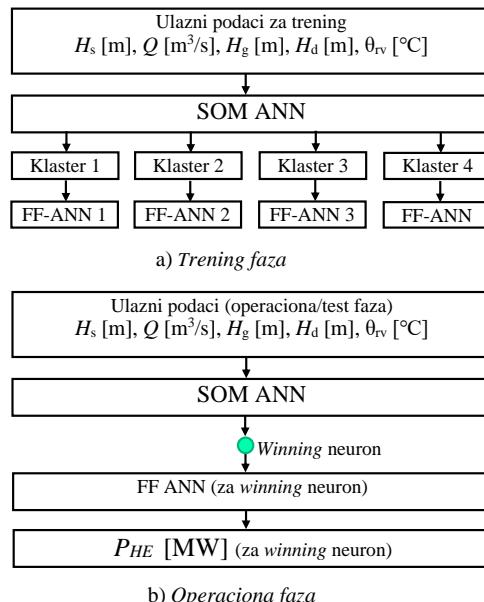
Kada izdvojimo stabilne i nestabilne intervale, sledi predikcija snage na izlazu HE. Za nestabilne intervale koristimo FF-ANN, dok za stabilne koristimo RNN. Ovako kreirani model efikasno „pamtii“ trenutke svakog predviđanja, čuvajući informacije o tome kada i po kom redosledu su određene snage predviđene. Ove informacije se potom „vraćaju“ u trenutke kada je potrebno izvršiti konačnu predikciju, omogućavajući da se kombinuju predikcije iz pojedinačnih mreža u zavisnosti od njihove relevantnosti u datim uslovima. Na ovaj način, rezultujuća snaga koja se dobija primenom kombinovanog modela ne samo da se efikasno prilagođava trenutnim promenama već i koristi podatke o prošlim stanjima, čime se postiže veća preciznost i pouzdanost krajnjeg rezultata.

Za svaki sezonski skup, posebno je treniran FF-ANN ili RNN model, sa istom arhitekturom i parametrima kao prvobitno kreirana mreža, kako bi se obezbedila konzistentna evaluacija performansi. Na ovaj način omogućeno je poređenje između sezonski specifičnih modela i prethodnog, jedinstvenog modela

treniranog na ograničenom periodu (aprila 2023), kao i analiza uticaja sezonske adaptacije na preciznost predikcije snage HE.

B. SOM klasterizacija ulaznih podataka

Kako bi se dodatno istražila struktura ulaznih podataka i otkrile nepoznate veze među njima, u radu je primenjena SOM mreža [7]. Ulazni vektor mreže čini pet pomenutih ulaznih veličina, koji su pre same obuke normalizovani u opsegu od 0 do 1. Arhitektura predložene SOM neuronske mreže je matrica dimenzije 2×2 , što čini četiri klastera. Za svaki klaster izdvajaju se ulazni i izlazni podaci, nakon čega se nad njima pojedinačno trenira FF-ANN model (Sl. 1a). Na taj način se postiže izolovano učenje mreže, tj. svaki ANN model uči obrasce ponašanja karakteristične za svoj klaster, bez potrebe za definisanjem kriterijuma ili nekih drugih pravova o granicama odgovarajućih grupa. Ovakav pristup omogućava finiju podelu podataka iz HE i otkriva grupe u podacima koje meteorološki kriterijum ne može da prepozna, čime se pruža potencijal za dalju analizu. U operacionoj fazi, novi ulazni podaci se klasifikuju u odgovarajući klaster, primenom SOM neuronske mreže, a zatim se predikcija izlazne snage P_{HE} dobija iz odgovarajuće FF-ANN, kao što je prikazano na Sl. 1b.



Sl. 1 Arhitektura SOM i FF neuronske mreže u trening i operacionoj fazi

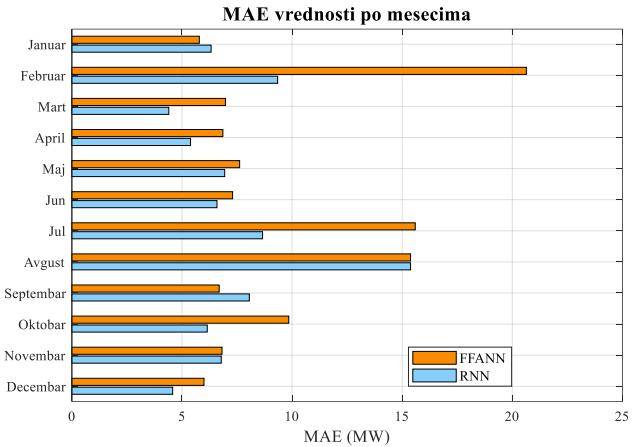
IV. EVALUACIJA MODELA

U ovom poglavljiju predstavljena je evaluacija performansi novih ANN modela kako bismo ih uporedili sa prvočitno kreiranim modelom. Cilj je da se kroz evaluacione metrike pokaže doprinos sezonske segmentacije i SOM klasterizacije u poboljšanju tačnosti i pouzdanosti predikcije snage HE tokom cele godine. Za procenu kvaliteta predviđanja korišćene su standardnih metrika – srednje apsolutne greške (*Mean Absolute Error* - MAE), srednje kvadratne greške (*Root Mean Squared Error* - RMSE) i koeficijenta determinacije R^2 .

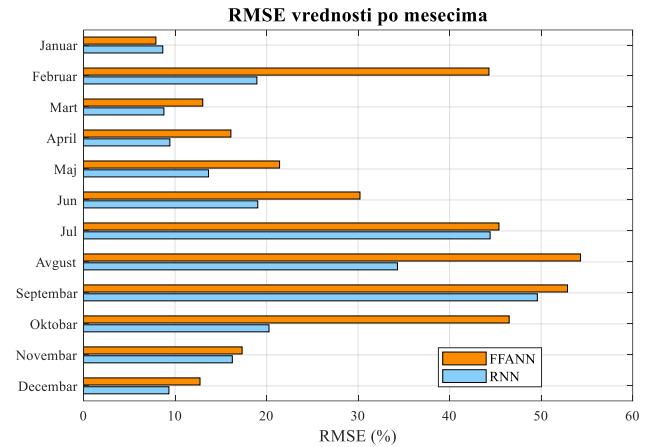
A. Evaluacija prethodnog FF-ANN i RNN modela

Rezultati u [2] su pokazali da FF-ANN postiže veću tačnost u uslovima kada dolazi do naglih i brzih promena protoka, zahvaljujući svojoj sposobnosti da trenutno reaguje na ulazne vrednosti bez potrebe za vremenskom memorijom. Nasuprot

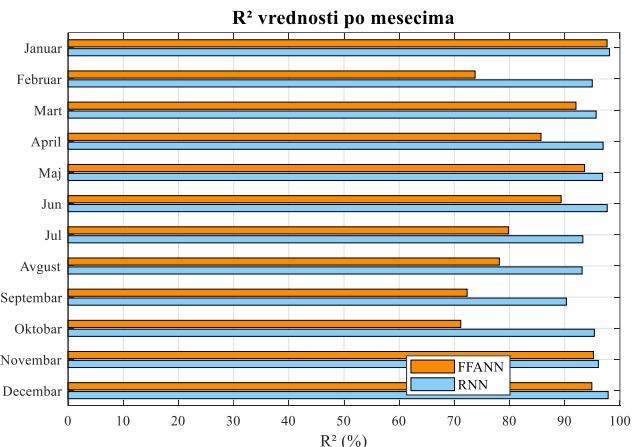
tome, RNN pokazuje superiorne performanse u slučajevima kada su promene protoka postepene i spore, oslanjajući se na sposobnost praćenja prethodnih stanja sistema. Ove osobine istakle su se u uslovima ograničenog broja podataka, ali je neophodno dodatno ispitati sposobnosti ova dva modela da generalizuju kada se testiranje vrši na znatno većem skupu podataka, odnosno na periodu od jedne godine, što je prikazano na Sl. 2, 3 i 4.



Sl. 2 Vrednosti MAE za prvočitni FF-ANN i RNN model tokom 2024. godine



Sl. 3 Vrednosti RMSE za prvočitni FF-ANN i RNN model tokom 2024. godine



Sl. 4 Vrednosti R^2 za prvočitni FF-ANN i RNN model tokom 2024. godine

Na osnovu vrednosti evaluacionih metrika zaključujemo da model kreiran u radu [2] ne pokazuje zadovoljavajuću tačnost u ovom slučaju.

Posmatrajmo FF-ANN model (narandžasta linija), MAE ni u jednom mesecu nema vrednost koja je manja od 5 MW, a u februaru iznosi čak 20,64 MW. Za isti model RMSE samo u januaru pada ispod 5 %, dok u nekim letnjim mesecima prelazi 50 %. R^2 nije metrika koja nužno pokazuje tačnost predikcije, već pokazuje koliko trend predviđenih vrednosti prati trend stvarne vrednosti snage. Vrednosti ispod 90 % su ovde nedopustive jer mogu uticati na pogrešne upravljačke odluke u HE. Rezultati evaluacionih metrika dobijeni primenom RNN modela pokazuju precizniju predikciju, ali nedovoljno dobru. Iz tog razloga, neophodno je korišćenje sezonski prilagođenih, adaptivnih ANN ili SOM ANN.

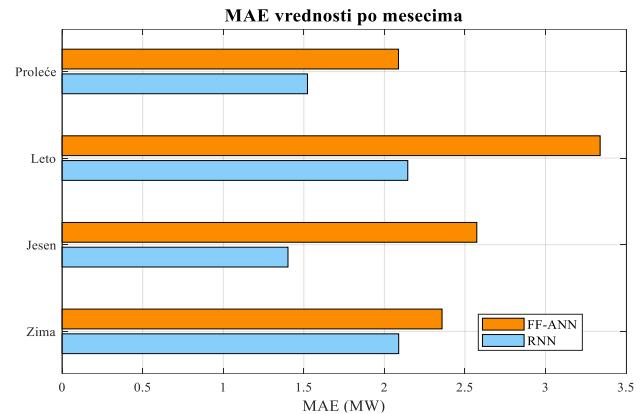
B. Evaluacija adaptivnih sezonskih FF-ANN i RNN modela

Za potrebe ovog istraživanja korišćeni su realni podaci iz protočne HE, pri čemu je na osnovu celokupnog godišnjeg skupa od 447.077 merenja prikupljenih tokom 2024. godine, za svako godišnje doba obrađeno preko 100.000 uzoraka, od kojih je 60 % iskorišćeno za treniranje, a 40 % za testiranje modela, dok podaci o samom izvoru nisu eksplisitno navedeni iz ugovornih i etičkih razloga, što ne utiče na validnost sprovedene analize.

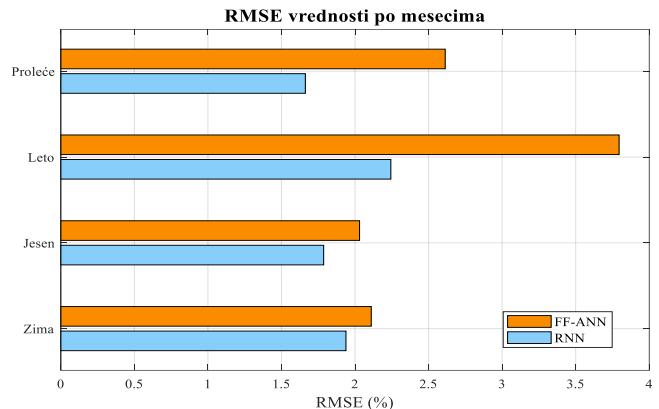
U fazi testiranja predloženog modela, izračunate su vrednosti MAE, RMSE i R^2 , za svaku sezonu, što je prikazano na Sl. 5, 6 i 7.

Rezultati evaluacije pokazuju da sezonski modeli ostvaruju bolje performanse u svim sezonom, u poređenju sa prvobitnim modelom (Sekcija IV.A) koji nije u stanju da se jednakobro prilagodi promenama za različite hidrometeorološke periode. Ovo je očekivano, jer je dosta više podataka iskorišćeno za treniranje adaptivnih sezonskih modela. Posebno je izraženo smanjenje MAE i RMSE tokom zimskog i letnjeg perioda, koje su sada manje od 3,5 MW, odnosno 4 %, respektivno. Metrika R^2 pokazuje da novi modeli izuzetno dobro prate trend stvarnih vrednosti, tokom jeseni, u mesecima septembar, oktobar i novembar ovaj parametar iznosi 98,69 %, a za prvobitno kreirani model iznose 90,3 %, 95,4 % i 96,09 %, respektivno (Sl. 4).

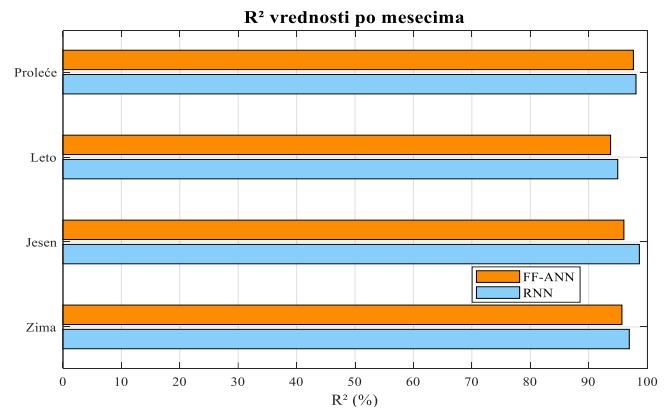
Na Sl. 8 prikazan je grafički rezultat FF-ANN/RNN modela za prolećnu sezonu u vidu poređenja stvarnih i predviđenih vrednosti izlazne snage HE, čime se vizuelno potvrđuje unapređena sposobnost sezonski treniranih modela da prate dinamičke promene u protoku vode kroz turbinu.



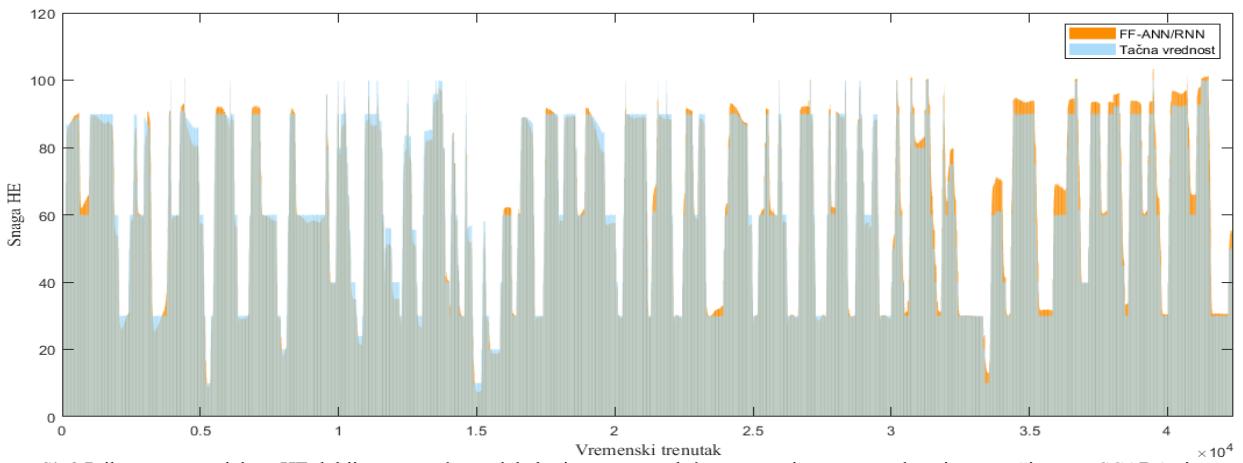
Sl. 5 Vrednosti MAE za sezonske FF-ANN i RNN modele



Sl. 6 Vrednosti RMSE za sezonske FF-ANN i RNN modele



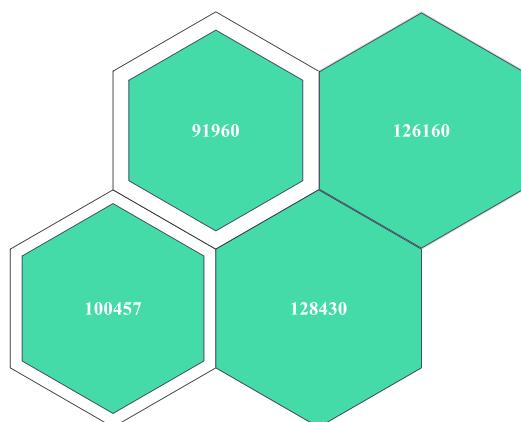
Sl. 7 Vrednosti R^2 za sezonske FF-ANN i RNN modele



Sl. 8 Prikaz snage na izlazu HE dobijene pomoću modela kreiranog za prolećnu sezonu i stvarne vrednosti snage očitane sa SCADA sistema

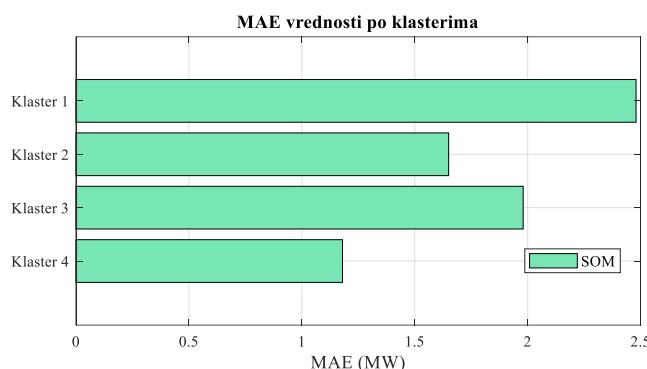
C. Evaluacija SOM ANN modela

Primenom SOM neuronske mreže ulazni podaci su, u trening fazi, klasifikovani u četiri klaster, kao što je prikazano na Sl. 9.

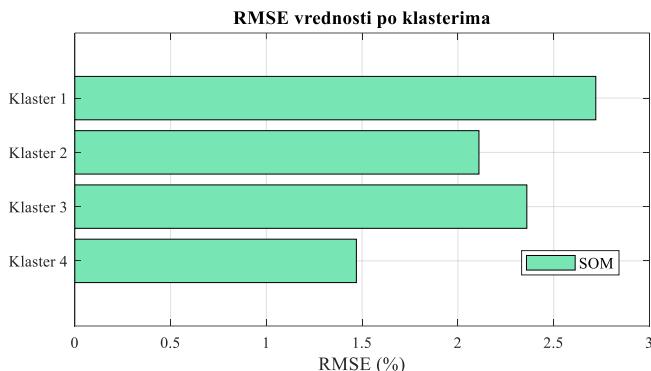


Sl. 9 Broj ulaznih podataka u pojedinačnim klasterima

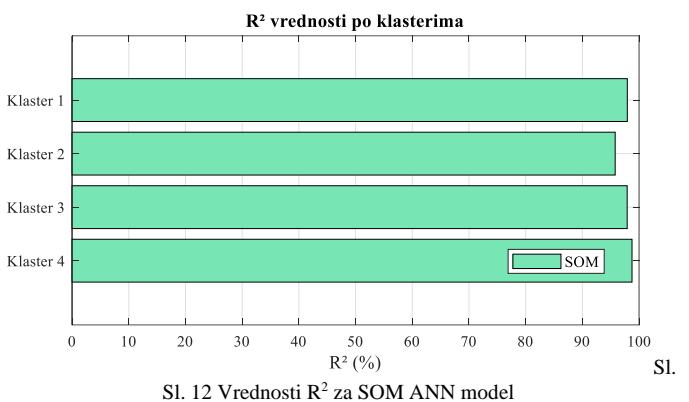
Za svaki klaster je trenirana zasebna FF-ANN. U test fazi, kao što je prikazano na Sl. 1b, test ulazni podaci su klasifikovani u odgovarajući klaster, a primenom FF-ANN je određena izlazna snaga P_{HE} . Za svaki klaster izračunate su vrednosti MAE, RMSE i R^2 , što je prikazano na Sl. 10, 11 i 12.



Sl. 10 Vrednosti MAE za SOM ANN model



Sl. 11 Vrednosti RMSE za SOM ANN model



Sl. 12 Vrednosti R^2 za SOM ANN model

Rezultati evaluacije ukazuju na superiornost SOM-ANN modela prema svim posmatranim evaluacionim metrikama. Uvođenjem SOM klasterovanja postiže se finija segmentacija podataka, pri čemu je svakom uzorku dodeljena pripadnost najadekvatnijem klasteru. Za razliku od sezonske podele, gde se može desiti da, na primer, podaci iz prolećnog perioda bolje odgovaraju mreži treniranoj za zimske uslove, SOM pristup omogućava preciznije reagovanje na takve promene, kao što je ranije otapanje snega. Dodatno, ovakva mrežna struktura se može lako proširiti na veći broj klastera, čime se dodatno povećava fleksibilnost i prilagodljivost modela.

V. ZAKLJUČAK

Rezultati dobijeni evaluacijom sezonski treniranih FF-ANN i RNN modela sa klaster analizom podataka o protoku kao i SOM ANN modela jasno ukazuju na svoje prednosti. Korišćenjem četiri nezavisna modela, prilagođena različitim hidrološkim uslovima tokom godine, postignuto je smanjenje grešaka predikcije u poređenju sa prvobitno kreiranim modelom koji nije u stanju da se jednako dobro adaptira dinamici rada HE. Sezonski pristup time doprinosi boljoj tačnosti i pouzdanosti modela jer omogućava stabilnije performanse u okviru svake jasno definisane sezone. Osim sezonske podele, SOM ANN modelom je omogućeno dodatno unapređenja modela kroz klasterizaciju podataka, posebno u kontekstu prepoznavanja netičkih perioda unutar jedne sezone. Takva klasifikacija, zasnovana na klaster analizi podataka, omogućava još finiju adaptaciju modela, čime se povećava njegova preciznost u predikciji i otpornost na lokalne promene.

Iako pojedinačni modeli nisu trenirani na podacima izvan posmatrane 2024. godine, postoje opravdani rezultati na osnovu kojih se može reći da bi i u tim slučajevima kreirani modeli pokazali visoke vrednosti koeficijenta determinacije i niske greške, što bi ukazalo na dobar stepen generalizacije unutar definisanih sezonskih granica.

ZAHVALNICA

Istraživanja prezentovana u ovom radu su delimično finansirana sredstvima Ministarstva nauke, tehnološkog razvoja i inovacija RS, ugovor br. 451-03-137/2025-03/200132 čiji je realizator Fakultet tehničkih nauka u Čačku - Univerziteta u Kragujevcu.

REFERENCE

- [1] H. Wang, L. Wang i L. Ma, „Anomaly Detection of Hydropower Bearing Based on Convolutional Neural Network Autoencoder“, IEEE 4th International Conference on Computer and Communication Engineering Technology, 2021, pp. 430-433, doi: 10.1109/CCET52649.2021.9544462.
- [2] Čubonović S, Ranković A, Krstić M, „The Application of Artificial Neural Networks for Predicting the Power Output of a Hydroelectric Power Plant“, Energija, Ekonomija, Ekologija, XXVI, br.2, 2024. doi:10.46793-eee24-2-47c
- [3] Nilanjan S, Aleena S, Mahadev M, „A Brief Review on Artificial Neural Network: Network Structures and Applications“, 9th International Conference on Advanced Computing and Communication Systems, 2023. doi: 10.1109/ICACCS57279.2023.10112753
- [4] Briliant.org, „Feedforward Neural Networks“, preuzeto 20. 4. 2025. sa sledeće adrese: <https://briliant.org/wiki/feedforward-neural-networks/>.
- [5] Hagan M. T, Demuth H. B, Bale M, „Neural Network Design“, Boston, USA: PWS Pub. Co. 1996.
- [6] Jain A.K, Murty M.N, Flynn P.J, „Data Clustering: A Review“, ACM Computing Surveys, Vol. 31, No. 3, 1999. <https://doi.org/10.1145/331499.331504>.
- [7] B. Sowmiya, and S. Amal Raj. "Review of the Self-Organizing Map (SOM) Approach in the Field of Environmental Engineering", 2016. International Journal of Soft Computing and Engineering,: Vol. 6, No. 4, 2016.

ABSTRACT

This paper represents a continuation of previous research on the application of Artificial Neural Networks (ANN) for the prediction of power output from a hydroelectric power plant, using two types of ANN: Feedforward Artificial Neural Networks (FF-ANN) and Recurrent Neural Networks (RNN). In the new approach, the volume of data used for model testing has been extended to cover an entire year. The annual dataset is divided into four seasonal segments based on meteorological criteria – spring, summer, autumn, and winter – with a separate adaptive ANN model developed for each season, along with an additional segmentation of data based on water flow dynamics. In order to improve the precision of operating regime segmentation, a Self-Organizing Map (SOM) network is also applied for data clustering, enabling better adaptation of the ANN models to various operating conditions. The aim of the paper is to further improve the precision and robustness of the models to allow better adaptability to the specific hydrological and operational conditions of each season. The testing results show that both the seasonal and SOM-based models outperform the model trained on a limited time period in terms of prediction accuracy. In this way, trust in the developed models is strengthened and opportunities for their further improvement are opened.

IMPROVING POWER OUTPUT PREDICTION IN HYDROELECTRIC POWER PLANT USING SEASONAL SEGMENTATION AND SOM DATA CLUSTERING METHOD

Stefan Čubonović, Aleksandar Ranković