

Primena veštačkih neuronskih mreža za predikciju snage na izlazu hidroelektrane

Stefan Čubonović*, Aleksandar Ranković*, Marko Krstić**

* Fakultet tehničkih nauka u Čačku, Univerziteta u Kragujevcu

** Javno preduzeće Elektroprivreda Srbije

Rezime - U ovom istraživačkom radu sprovedena je analiza dva tipa veštačkih neuronskih mreža (*Artificial Neural Network* – ANN) za predikciju snage na izlazu hidroelektrane (HE). Prvi tip je veštačka neuronska mreža sa jednosmernim prostiranjem signala (*Feedforward Artificial Neural Networks* – FF-ANN), dok je drugi tip rekurentna neuronska mreža (*Recurrent Neural Network* – RNN). Detaljno su analizirani koraci koji su preduzeti u procesu implementacije neuronskih mreža za ovu svrhu, od prikupljanja i pripreme podataka do treniranja, evaluacije i analize rezultata. Kao ulazni podaci korišćeni su neto pad, protok vode kroz turbinu, kota gornje vode, kota donje vode i temperatura ulazne rashladne vode. Na osnovu koeficijenta korelacije pojedinih veličina iz ulaznog sloja sa izlaznom snagom izvršena implementacija novih ANN. Rezultati dobijeni ovim varijacijama su sistematski analizirani kako bi se postiglo što preciznije modelovanje, sa akcentom na dinamičke promene u protoku vode kroz turbinu.

Cljučne reči - veštačka neuronska mreža, FF-ANN, RNN, hidroelektrana, izlazna snaga


I UVOD

Uzimajući u obzir imperativ održive ravnoteže i neodložne potrebe za „zelenom“ i pouzdanom energijom, HE zadržavaju ključnu poziciju u svetskom energetsom okruženju. Ovim se njihova značajnost ne ograničava samo na generisanje električne energije, već pruža i osnovu za prelazak ka održivijoj budućnosti u oblasti energetike.

HE koriste potencijal akumulirane energije vode za generisanje električne energije. Kada su u pitanju protočne HE (Slika 1), one koriste kinetičku energiju neprekidnog toka vode, pretvarajući je u mehaničku rotacionu energiju na lopaticama turbina koja se potom pretvara u električnu energiju posredstvom generatora (proces konverzije). Snaga ovih HE zavisi od protoka vode, a za pokretanje generatora koriste se najčešće Kaplanove i Fransisove turbine. Iako suočene sa varijabilnim protokom, protočne HE imaju ključnu ulogu u održavanju fleksibilnosti EES-a. Istraživanje u ovom radu sprovedeno je sa realnim podacima jedne protočne HE čiji detaljni podaci, uključujući naziv, lokaciju i tehničke specifikacije nisu navedeni zbog poštovanja tajnosti podataka. Prethodno pomenuto neće uticati na analizu ANN, što je u fokusu ovog rada.

Primena ANN kao izuzetnog alata za analitičko istraživanje i prediktivno modelovanje se sve više koristi za analizu složenih sistema. Kroz sposobnost da oponašaju interakcije između

neurona u ljudskom mozgu, ove mreže pružaju sposobnost otkrivanja dubokih uzoraka u podacima i izvođenja kompleksnih predviđanja učeći složene i nelinearne veze između različitih ulaznih podataka čak i ako na prvi pogled ti podaci ne deluju povezano [1], kao što je slučaj sa pojedinim veličinama u posmatranom primeru. S obzirom na njihovu sposobnost adaptacije i učenja iz iskustva, ANN postaju vredan resurs u prevazilaženju izazova vezanih za energetiku, posebno u procesu estimacije stanja, u pseudo merenjima [2], kao na primer predikcija izlazne snage HE na osnovu podataka koji ne moraju ključno imati direktan uticaj na istu. Uvođenje ovog inteligentnog alata pomera granice tradicionalnog analitičkog pristupa i ima potencijal za stvaranje pouzdanog i efikasnog rešenja u domenu energetike.



Slika 1. Tipični prikaz protočne hidroelektrane

Predikcija snage HE pomoću ANN je ideja koju su istraživači u radu [3] već razvili. Međutim, u poređenju sa tim radom, autori ovog rada primenili su dodatni model ANN za predikciju snage – RNN. Zatim, ulazne veličine u radu [3] su direktno zavisne od izlazne snage i na osnovu njih se izlazna snaga može odrediti i analitičkim putem, dok je doprinos ovog rada predviđanje izlazne snage na osnovu veličina koje nisu direktno povezane sa njom, poput temperature ulazne rashladne vode. Dodatno, analizom rezultata u ovom radu pokazano je koji od dva modela daje veću tačnost u različitim uslovima rada, na osnovu toga dat je predlog optimalnog modela ANN za buduće istraživanje.

U cilju traganja za sve efikasnijim načinima optimizacije HE i estimacije stanja EES-a, u ovom radu je razvijen jednostavan i precizan model za predikciju izlazne snage HE zasnovan na primeni ANN, sa podacima koji se mogu dobiti iz SCADA sistema svake HE. U II poglavlju detaljno su opisani modeli neuronskih mreža koji su primenjeni u ovom radu, pokazane su njihove specifičnosti i međusobne razlike. U III poglavlju predstavljen je detaljan opis prikupljanja i analize

karakterističnih veličina i dat je izraz za proračun izlazne snage koji je osnov za razvoj našeg modela. U narednom, IV, poglavlju dat je pregled metrika evaluacije i jedne metrike bitne za analizu u poglavlju VI. Ključni deo prikazan je u V poglavlju istraživačkog rada, gde je različitim, prethodno pomenutim, metrikama evaluacije potvrđena tačnost proračuna, sa osvrtom na implementaciju i arhitekturu primenjenih ANN u softverskom alatu MATLAB. U sledećem, poglavlju VI, izostavljanjem pojedinih karakterističnih veličina u ulaznom sloju, urađena je dodatna analiza značajnosti ulaznih promenljivih, posebno protoka, na performanse razvijenih modela. U poglavlju VII su dati glavni zaključci do kojih se došlo u ovom radu.

II IMPLEMENTACIJA VEŠTAČKIH NEURONSKIH MREŽA KROZ MATLAB

U opštem slučaju postoje tri vrste slojeva kod ANN-a [4]:

1. ulazni sloj (*Input Layer*),
2. skriveni sloj (*Hidden Layer*),
3. izlazni sloj (*Output Layer*).


Ulazni 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. Važno je napomenuti da ulazne veličine često zahtevaju normalizaciju ili standardizaciju pre nego što se prenesu mreži kako bi se osigurala stabilnost i konvergencija prilikom obuke, neki softverski alati u funkcijama za pozivanje ANN već imaju deo koji normalizuje podatke. Na primer, u MATLAB-u, funkcija *feedforwardnet* automatski uključuje normalizaciju podataka koristeći podrazumevanu funkciju *mapminmax*. Ovo je posebno bitno kada se koriste različiti tipovi podataka ili kada su vrednosti veličina na različitim skalama.

Broj slojeva, kao i broj neurona u skrivenim slojevima, predstavlja ključne parametre koji oblikuju tačnost i preciznost mreže [5]. Odabir optimalnih vrednosti za ove parametre predstavlja kritičan deo dizajna same mreže i zavisi prvenstveno od prirode problema koji se rešava, kao i od karakteristika i veličine dostupnog skupa podataka. Na primer, dodavanje više neurona u skrivenom sloju omogućava mreži da uči složenije odnose između podataka, što je naročito važno kod nelinearnih problema. Međutim, treba voditi računa da prevelik broj neurona u skrivenom sloju ima suprotan efekat (*Overfitting*) na tačnost ANN [6] jer se u tom slučaju javlja pre-trening (*Overtraining*) ANN [7]. Dakle, za odabir optimalnog broja neurona u skrivenom sloju preporučuje se iterativno testiranje koje će rezultirati što tačnijem modelu.

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 - izlazna snaga.

Prvi korak u implementaciji ANN kroz MATLAB je pažljiv odabir ulaznih i izlaznih veličina, priprema i učitavanje tih veličina i na kraju njihova obrada. Ovaj korak takođe podrazumeva podelu podataka na skupove za trening (60 % ukupnih podataka), validaciju i testiranje (40 % ukupnih

podataka). U drugom koraku, potrebno je definisati arhitekturu ANN, birajući broj slojeva i neurona u svakom sloju. Treći korak je treniranje, koje se sprovodi koristeći funkciju za obuku, gde se prate metrike performansi (Slika 2), radi prikaza data je slika samo jednog tipa mreže. Na kraju se evaluiraju performanse mreže na nezavisnom skupu za testiranje i vrši se optimizacija radi postizanja boljih rezultata.



Slika 2. Praćenje metrike performansi FF-ANN u MATLAB-u tokom procesa treniranja

U ovom radu analiziraćemo dva tipa ANN i oba modela u svojoj implementaciji sadrže prethodna četiri koraka, uključujući evaluaciju. Međutim, već u drugom koraku način rada može biti različit u zavisnosti od primenjenog modela, čije će specifičnosti biti prikazane u nastavku.

Prvi model je veštačka neuronska mreža sa jednosmernim prostiranjem signala - FF-ANN. Usled inherentne prirode problema u ovom istraživanju, preporučuje se primena FF-ANN kao, pretpostavljenog, najadekvatnijeg tipa ANN za rešavanje pomenutog izazova, što ćemo u poglavlju V dodatno analizirati. Glavna karakteristika mreža ovog tipa jeste da zavisnost između podataka nije ciklična. Naime, signali na izlazu isključivo zavise od signala na ulazu, a ne od prethodne vrednosti izlaza – nemaju povratnu petlju, smer signala je unapred od ulaza ka izlazu [4].

Signal na izlazu FF-ANN (y_j) se dobija kao rezultat sledeće aktivacione formule [8]:

$$y_j = f \left(\sum_{i=1}^n (w_{ij} x_i + \theta_j) \right), \quad (1)$$

gde su:

y_j - izlazna veličina (*output variable*),

j - broj neurona u skrivenom sloju,

i - indeks ulazne veličine,

n - broj neurona u prethodnom sloju,

w_{ij} - težinski faktori između veličine i i j (*weight values*),

x_i - ulazna veličina i -tog neurona (*input variables*),

θ_j - vrednost pragova (nagiba) aktivacione funkcije veličine j (*bias*).

Grafički prikaz arhitekture primenjene FF-ANN dat je na Slici 3 a).

Drugi tip modela primenjen u ovom radu je rekurentna neuronska mreža - RNN. RNN ima povratnu petlju koja omogućava pamćenje prethodnih stanja. U ovim mrežama postoji povratna veza koja omogućava informacijama da kruže unazad kroz neuronsku mrežu, što znači da se prethodno izračunata izlazna veličina koristi kao jedna od ulaznih veličina za sledeći korak u treniranju i testiranju neuronske mreže. Problem kod ovih mreža može se javiti kada se informacija prenosi kroz mnogo vremenskih koraka, zbog čega dolazi do problema nestajućeg i eksplodirajućeg gradijenta [9]. Matematički model za izlazni signal u trenutku t iz RNN prikazan je sledećom jednačinom [6]:

$$y_j^t = f \left(\sum_{i=1}^n (w_{ij} x_i^t + u_{ij} y_j^{t-1} + \theta_j) \right), \quad (2)$$

gde su:

y_j^t - izlazna veličina u trenutku t (output variable),

t - trenutni vremenski korak,

j - broj neurona u skrivenom sloju,

i - indeks ulazne veličine,

n - broj neurona u prethodnom sloju,


w_{ij} - težinski faktori između veličine i i j (weight values),

x_i^t - ulazna veličina i -tog neurona u trenutku t (input variables),

u_{ij} - težinski faktori između veličite i i j u prethodnom vremenskom koraku ($t-1$),

y_j^{t-1} - izlazna veličina u koraku ($t-1$),

θ_j - vrednost pragova (nagiba) aktivacione funkcije (bias) j -tog neurona.



Slika 3. Ilustracija arhitekture primenjenih ANN
a) FF-ANN, b) RNN

U ovom modelu ulazne veličine x_i^t i izlazna veličina u trenutku ($t-1$) y_j^{t-1} doprinose izlazu y_j^t . Bitno je napomenuti da RNN ima sposobnost očuvanja informacija o prethodnim vremenskim koracima, što ga čini pogodnim za rad sa sekvencijalnim podacima.

Grafički prikaz arhitekture primenjene RNN dat je na Slici 3 b).

III PRIKUPLJANJE I PRIPREMA PODATAKA

Ulazni i izlazni sloj su ključni za modelovanje i analizu sistema primenom ANN. Ovi slojevi čine određene veličine koje se mogu dobiti iz različitih izvora, najčešće su to merenja sa senzora na samoj HE ili meteoroloških stanica. Veličine u ulaznom sloju se koriste za treniranje neuronske mreže i čine osnovu za njen rad. Za kreiranje i testiranje ANN-a u ovom radu korišćeno je više desetina hiljada podataka iz aprila 2023. godine. Podaci predstavljaju skup sledećih veličina za dati vremenski period sa vremenskom diskretizacijom od jednog minuta:

1. statički pad - H_s [m],
2. protok vode kroz jednu turbinu - Q [m³/s],
3. kota gornje vode - H_g [m],
4. kota donje vode - H_d [m],
5. temperatura ulazne rashladne vode - θ_{rv} [°C].

Tabela 1. Ulazni i izlazni podaci neophodni za kreiranje ANN

Vremenski trenutak	H_s [m]	Q $\left[\frac{m^3}{s}\right]$	H_g [m]	H_d [m]	θ_{rv} [°C]	P_H [MW]
1. 4. 2023.						
00.00.01	20,45	4·84	156,34	135,83	9,79	59,79
00.00.02	20,45	4·84	156,33	135,83	9,79	60,17
⋮						
30. 4. 2023.						
00.58.00	19,77	4·175,96	157,11	137,16	10,74	123,09
00.59.00	19,77	4·175,96	157,11	137,13	10,74	123,02

Od prethodno pomenutih veličina, jedino su međusobno zavisne statički pad, kota gornje vode i kota donje vode. Između ovih veličina važi sledeća relacija [10]:

$$H_s = H_g - H_d \quad (3)$$

Snaga izvučena iz kinetičke energije vodenog toka je u skladu sa jednačinom (4) [11]:

$$P = \eta \cdot \rho \cdot g \cdot Q \cdot H_n \quad (4)$$

gde su:

- P_H - snaga na izlazu HE [W],
- η - stepen iskorišćenja procesa konverzije,
- ρ - gustina vode, najčešće se usvaja 1000 kg/m^3 ,
- g - gravitaciono ubrzanje, $9,81 \text{ m/s}^2$,
- Q - protok vode kroz turbinu [m^3/s],
- H_n - neto pad [m].

IV METRIKE ZA EVALUACIJU I ANALIZU REZULTATA

U kontekstu ANN, evaluacija se odnosi na procenu ponašanja modela sa nepoznatim ulaznim podacima [11,12], tj. koliko dobro model generalizuje naučene obrasce na novim ulaznim podacima. To se može postići upotrebom različitih metrika za procenu, kao što su srednja apsolutna greška (*Mean Absolute Error* - MAE), srednja kvadratna greška (*Root Mean Squared Error* - RMSE), koeficijent determinacije (R^2) i druge relevantne metrike za specifični problem.

Prva metrika koja je primenjena za evaluaciju rezultata jeste proračun MAE. Ova greška izračunava se pomoću formule (5) i predstavlja prosečnu apsolutnu razliku između stvarnih i predviđenih vrednosti. Rezultat ove greške je u istoj jedinici kao originalni podaci. Dakle, ako je izlazna snaga izražena u [MW], MAE će biti izražena u [MW].

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |P_{Hi} - P_{ANNi}| \quad (5)$$

gde su:

- N - ukupan broj merenja,
- P_{Hi} - tačna vrednost dobijena iz HE [MW],
- P_{ANNi} - predviđena vrednost dobijena primenom ANN [MW].

Ova metrika je važna prilikom validacije modela jer pruža jasno merilo tačnosti. Veća vrednost ove greške ukazuje na nisku tačnost u merenju, dok niža vrednost ukazuje na visoku tačnost kreiranog modela.

Druga metrika merodavna za evaluaciju kreiranog modela je RMSE, računa se pomoću formule (6). Da bi se olakšala diskusija o tačnosti kreiranog modela ovu grešku ćemo u poglavlju V prikazati u procentima.

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_{Hi} - P_{ANNi})^2} \quad (6)$$

Vrednost ove greške može da pruži uvid u kvalitet merenja ili performanse modela, ali interpretacija konkretne vrednosti zavisi od konteksta problema i veličine podataka koji se analiziraju.

Kvadrat koeficijenta korelacije (R^2), koristi se za evaluaciju performansi modela tako što meri koliko dobro se model

prilagođava stvarnim podacima i ovo je treća metrika za koju ćemo primeniti za evaluaciju rezultata. R^2 može imati vrednosti između 0 i 1, gde veće vrednosti ukazuju na bolje prilagođavanje modela stvarnim podacima. Postupak izračunavanja je sledeći:

$$R^2 = \left(1 - \frac{\sum_{i=1}^N (P_{Hi} - P_{ANNi})^2}{\sum_{i=1}^N (P_{Hi} - \hat{P}_{Hi})^2} \right) \cdot 100[\%], \quad (7)$$

gde $\hat{P}_{Hi}$ predstavlja srednju vrednost stvarne vrednosti snage.

Dobijena vrednost R^2 može se interpretirati na sledeći način:

- $R^2 = 1$ (100 %): predviđeni podaci savršeno odgovaraju stvarnim podacima,
- $0 < R^2 < 1$: predviđeni podaci odgovaraju stvarnim podacima u određenoj meri, gde veće vrednosti ukazuju na bolje prilagođavanje,
- $R^2 = 0$: model ne pruža nikakvu poboljšanu predikciju u odnosu na prosečnu vrednost stvarnih podataka.

Mera da li su pojedini parametri u korelaciji pokazaće koeficijent korelacije (r). Koeficijent korelacije je statistička mera koja se koristi za merenje jačine i pravca linearnog odnosa (korelacije) između dve veličine. Izračunava se pomoću formule (8).

$$r = \frac{N \sum_{i=1}^N (x_i \cdot P_{Hi}) - \sum_{i=1}^N x_i \sum_{i=1}^N P_{Hi}}{\sqrt{N \sum_{i=1}^N x_i^2 - \left(\sum_{i=1}^N x_i \right)^2} \cdot \sqrt{N \sum_{i=1}^N P_{Hi}^2 - \left(\sum_{i=1}^N P_{Hi} \right)^2}}, \quad (8)$$

gde x_i predstavlja vrednost jedne od veličina ulaznog sloja (H_s , Q , H_g , H_d ili θ_{rv}).

Ovaj koeficijent može da varira između -1 i 1, a to ima sledeće zčenje:

- ako je $r=1$: savršen pozitivan linearni odnos između veličina, što znači da rast jedne, proporcijalno prati rast druge veličine,
- ako je $r=-1$: savršen negativan linearni odnos između veličina, što znači da rast jedne, proporcijalno prati pad druge,
- ako je $r=0$: odsustvo linearnog odnosa između veličina.

Što je apsolutna vrednost koeficijenta korelacije bliža 1, to je jači linearni odnos između promenljivih. Oznaka "+" ili "-" ispred vrednosti r ukazuje na smer korelacije (pozitivan ili negativan).


V PRIKAZ I EVALUACIJA REZULTATA

V.I Rezultati dobijeni primenom FF-ANN

Kao rezultat izvršenja programa kreiranog pomoću prvog modela veštačke neuronske mreže – FF-ANN prikazan je grafik poređenja predviđene snage i stvarne vrednosti snage očitane sa SCADA sistema - Slika 4. Rezultati evaluacije primenom različitih, pomenutih, metrika prikazani su u Tabeli 2.

Za predstavljenu ANN, vrednost MAE iznosi 1,68 MW. Imajući u vidu da su stvarne vrednosti snage unutar opsega od 59,65 MW

do 124,48 MW za mesec koji je analiziran, zaključujemo da je programirani model pokazao izuzetnu sposobnost predviđanja. Tabela 2 pruža detaljan prikaz rezultata, RMSE iznosi 1,81 %, dok kvadrat koeficijenta korelacije, R^2 , iznosi 98,37 %. Kombinacija ovih metrika doprinosi boljem razumevanju performansi modela i omogućava sveobuhvatnu evaluaciju efikasnosti modela u odnosu na varijacije podataka, dok rezultati nedvosmisleno ukazuju da programirani model ostvaruje visok stepen preciznosti u predviđanju izlazne snage HE. Ipak, rezultati mogu biti dodatno poboljšani drugim modelom.




Slika 4. Prikaz snage na izlazu HE dobijene pomoću FF-ANN i stvarne vrednosti snage očitane sa SCADA sistema

Tabela 2. Evaluacija rezultata primenom različitih metrika za FF-ANN arhitekturu neuronske mreže

Metrika evaluacije	Vrednost greške
MAE [MW]	4,31
RMSE [%]	4,44
R^2 [%]	91,02

V.II Rezultati dobijeni primenom RNN



Slika 5: Prikaz snage na izlazu HE dobijena pomoću RNN i stvarne vrednosti snage očitane sa SCADA sistema

RNN prevazilazi FF-ANN u analizi sekvencijalnih podataka, ističući se po sposobnosti obrade informacija koje evoluiraju kroz vremenske korake, što doprinosi preciznijim predviđanjima. Kao rezultat izvršenja programa kreiranog pomoću drugog modela veštačke neuronske mreže prikazan je grafik poređenja predviđene snage i stvarne vrednosti snage očitane sa SCADA sistema - Slika 5. Rezultati evaluacije primenom različitih metrika prikazani su u Tabeli 3.

Tabela 3. Evaluacija rezultata primenom različitih metrika za RNN arhitekturu neuronske mreže

Metrika evaluacije	Vrednost greške
MAE [MW]	1,14
RMSE [%]	1,44
R^2 [%]	98,79

Za ovakvu arhitekturu ANN MAE iznosi 1,14 MW. Znajući da su stvarne vrednosti u ovom modelu, za mesec koji posmatramo, u opsegu od 59,65 MW do 124,48 MW, možemo zaključiti da programiran model daje dobra predviđanja. Za lakše poređenje rezultata dobijenih iz modela i tačnih vrednosti, u Tabeli 3 su prikazane i vrednosti parametara primenom različitih metrika. RMSE je 1,44 MW, R^2 iznosi visokih 98,79 %. Kombinacija ovih metrika pruža bolje razumevanje performansi modela i na osnovu dobijenih rezultata možemo reći da programiran model daje dobre rezultate u predviđanju izlazne snage HE.

VI ANALIZA ZNAČAJNOSTI ULAZNIH PROMENLJIVIH NA PERFORMANSE RAZVIJENIH MODELA

ANN ima sposobnost da nauči složene i nelinearne veze između različitih ulaznih podataka čak i ako na prvi pogled ti podaci ne deluju povezano. U sledećem delu ćemo ispitati korelisanost između veličina iz ulaznog sloja i izlazne veličine. Potom ćemo veličine koje su u najmanjoj i najvećoj korelaciji sa izlaznom snagom, pojedinačno isključiti iz prvobitne arhitekture ANN i izvršiti evaluaciju bez tog parametara. Na ovaj način ćemo proveriti koliko veličine koje naizgled nisu, odnosno jesu, u vezi sa snagom HE utiču na tačnost predikcije ANN.

U Tabeli 4 prikazane su vrednosti koeficijenta korelacije između svih pojedinačnih veličina iz ulaznog sloja i izlazne veličine neuronske mreže. Analizirajući ove koeficijente, možemo zaključiti da donja kota vode i protok kroz turbinu predstavljaju **ulazne** promenljive koje pokazuju najveću korelaciju sa izlaznom snagom. Nasuprot tome, temperatura ulazne rashladne vode i gornja kota vode pokazuju manju vezanost za promene u izlaznoj snazi. Dodatno, u prilogu ovim rezultatima, na Slici 6 prikazane su relativne promene svih ovih veličina, na osnovu analize 400 uzoraka.

Tabela 4. Koeficijenti korelacije za ulazne parametre i izlaznu snagu HE


x_i	H_n [m]	Q $\left[\frac{m^3}{s}\right]$	H_g [m]	H_d [m]	θ_{rv} [°C]
P_H [MW]					
$r(x_i, P_H)$ [%]	86,8	87,1	13,7	98,2	31,3

Prethodno navedeni rezultati detaljno prikazuju odnos između ulaznih i izlaznih veličina u okviru analiziranog sistema. U sledećim ANN će se ispitati da li odsustvo ulazne promenljive sa većim koeficijentom korelacije (Q) ili sa manjim koeficijentom korelacije (θ_{iv}) utiče na vrednost predviđene izlazne snage. Za izbor ova dva parametra odlučeno je na osnovu Jednačine (1), Tabele 4 i Slike 6.

Tabela 5. Evaluacija rezultata primenom različitih metrika kada je protok kroz turbinu izostavljen iz ulaznog sloja

Metrika evaluacije	Vrednost greške
MAE [MW]	4,31
RMSE [%]	4,43
R^2 [%]	89,76

U Tabeli 5 prikazani su rezultati u slučaju kada je protok kroz turbinu izostavljen kao veličina ulaznog sloja. Arhitektura ove neuronske mreže ima 4 veličine u ulaznom sloju, 8 neurona u skrivenom sloju i jednu veličinu u izlaznom sloju. Protok kroz turbinu je, posmatrajući Jednačinu (4), Tabelu 4 i Sliku 6, veličina koja najbliže prati promenu snage, zbog čega su i očekivani lošiji rezultati potvrđeni.





Slika 6. Relativne promene veličina iz ulaznog i izlaznog sloja na osnovu analize 400 uzoraka

Tabela 6. Evaluacija rezultata primenom različitih metrika kada je temperatura rashladne vode izostavljena iz ulaznog sloja

Metrika evaluacije	Vrednost greške
MAE [MW]	1,59
RMSE [%]	1,97
R^2 [%]	97,96


U Tabeli 6 prikazani su rezultati u slučaju kada je temperatura rashladne vode izostavljena kao veličina ulaznog sloja ANN. Arhitektura ove neuronske mreže ima 4 veličine u ulaznom sloju, 8 neurona u skrivenom sloju i jednu veličinu u izlaznom sloju. Temperatura rashladne vode je, posmatrajući Jednačinu (4), Tabelu 4 i Sliku 6, veličina koja najmanje utiče na izlaznu snagu. Očekivano, rezultati primenom različitih metrika evaluacije pokazuju da izostavljanje podatka o temperaturi rashladne vode neće mnogo uticati na vrednost izlazne snage.



Slika 7. Poređenje dobijenih izlaznih snaga primenom FF-ANN – a) i RNN – b) za spore i postepene promene protoka

Tokom ove analize primećeno je specifično ponašanje pomenutih modela ANN koje će biti obrazloženo u nastavku. Protok, kao veličina koja ima izuzetan uticaj na predikciju snage na izlazu HE, tokom posmatranog perioda može varirati ili imati približno konstantnu vrednost u određenim vremenskim intervalima. Logično, izlazna snaga prati te promene, a u narednom delu

pokazaćemo kako se pojedini tipovi ANN prilagođavaju tim promenama. Posmatrajmo slučaj kada su promene protoka spore i postepene. Takav je vremenski interval prikazan na Slici 7, gde su predstavljeni grafici poređenja izlazne snage HE, dobijene korišćenjem FF-ANN (a) i RNN (b) sa stvarnim vrednostima snage izmerenih putem SCADA sistema. Na osnovu prikazanih rezultata, primećujemo da je RNN arhitektura ostvarila preciznije rezultate u poređenju sa FF-ANN tokom analiziranog perioda. To je zbog povratne sprege koja je u arhitekturi ove mreže.



Slika 8. Poređenje dobijenih izlaznih snaga primenom FF-ANN – a) i RNN – b) za brze i nagle promene protoka

Suprotno, u slučaju brzih i naglih promena protoka, kakav je vremenski interval na Slici 8, osobina RNN da “pamti” prethodnu informaciju negativno utiče na predviđanje snage. U ovakvim slučajevima jednostavna arhitektura i jednosmerni tok predviđanja podataka, kakav je kod FF-ANN se pokazao kao bolje rešenje – Slika 8.

Možemo zaključiti da je korišćenje FF-ANN bolje za predikciju snage HE kada su promene protoka vode kroz turbinu nagle i brze, dok je korišćenje RNN bolje kada su promene protoka vode kroz turbinu spore i postepene. Klasterovanje podataka na periode odgovarajuće promene protoka a potom primena kombinacije FF-ANN i RNN predlog je optimalnog modela ANN za predikciju snage na izlazu HE.

VII ZAKLJUČAK

Korišćenje FF-ANN je preciznije za predikciju snage HE kada su promene protoka vode kroz turbinu nagle i brze, jer FF-ANN dobro obavlja predviđanje u situacijama kada trenutne veličine iz ulaznog sloja direktno utiču na izlaznu veličinu, bez uzimanja u obzir prethodnog stanja sistema. Ovo je posebno korisno u situacijama kada su promene veličina u ulaznom sloju nagle prirode.

S druge strane, kada su promene protoka vode kroz turbinu postepene i spore, korišćenje RNN pokazalo se kao preciznije rešenje, jer mreže ovog tipa poseduju sposobnost adekvatnog reagovanja na postepene i spore trendove u podacima.

Koeficijent determinacije R^2 , zajedno sa MAE i RMSE, omogućava dublju analizu tačnosti modela u odnosu na stvarne podatke. Na osnovu tih metrika evaluacije možemo reći da oba kreirana modela – FF-ANN i RNN daju dobre rezultate.

Uzimajući u obzir promenljivu prirodu protoka, kao preporuku autori su postavili ideju o klasterovanju podataka kako bi se osiguralo poverenje u preciznost modela u svim uslovima rada i svih tipova HE, koji će u sebi sadržati kombinaciju FF-ANN i RNN modela neuronskih mreža. Takođe, proširenje analize na duži vremenski interval ili na više HE dodatno bi povećalo robusnost rezultata. Ove preporuke ostaju kao podsticajne smernice za buduća istraživanja.

ZAHVALNICA

Istraživanja prezentovana u ovom radu su delimično finansirana sredstvima Ministarstva nauke, tehnološkog razvoja i inovacija RS, ugovor br. 451-03-66 / 2024-03 / 200132 čiji je realizator Fakultet tehničkih nauka u Čačku - Univerziteta u Kragujevcu.

LITERATURA/REFERENCES

- [1] Ranković, A., Maksimović, B.M., Sarić, A.T., Lukić, U. ANN-based correlation of measurements in micro-grid state estimation, International Transactions on Electrical Energy Systems, Vol. 25, No. 10, pp. 2181-2202, 2015. <https://doi.org/10.1002/etep.1956>
- [2] Warnick, C.C. *Hydropower Engineering*, Prentice Hall, 1984.
- [3] Thaeer, H.A., Mohd, H.B.S.N., Abdalla, A. Prediction of small hydropower plant power production in Himreen Lake dam (HLD) using artificial neural network, Alexandria Engineering Journal, Vol. 57, No. 1, pp. 211-221, 2018. <https://doi.org/10.1016/j.aej.2016.12.011>
- [4] Artificial Neural Networks: An introduction to ANN theory and practice, in: Braspenning, P.J., Thuijsman, F., Weijters, A.J.M.M. (Ed.), *Lecture Notes in Computer Science*, Vol. 931, Springer-Verlag, Berlin Heidelberg, 1995.
- [5] McGonagle, J., Garcia, J.A., Mollick, S. Feedforward Neural Networks, <https://brilliant.org/wiki/feedforward-neural-networks/> [preuzeto 21.11.2023]
- [6] Hagan, M.T., Demuth, H.B., Bale, M. *Neural Network Design*, PWS Pub. Co., Boston, USA, 1996.
- [7] Lawrence, S., Giles, C.L., Tsoi, A.C. Lessons in neural network training: overfitting may be harder than expected, in Proc. *Proceedings of the*

- Fourteenth National Conference on Artificial Intelligence and Ninth Innovative Applications of Artificial Intelligence Conference*, Providence, Rhode Island, pp. 540-545, 1997. https://cigiles.ist.psu.edu/papers/AAAI-97/overfitting.hard_to_do.pdf [preuzeto 21.11.2023]
- [8] Hansen, L.K., Salamon, P. Neural network ensembles, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 12, No. 10, pp. 993-1001, 1990. <https://doi.org/10.1109/34.58871>
- [9] Hochreiter, S. The vanishing gradient problem during learning recurrent neural nets and problem solutions, *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, Vol. 06, No. 02, pp. 107-116, 1998. <https://doi.org/10.1142/S0218488598000094>
- [10] Đurić, M., Đurišić, Ž., Čukarić, A., Ilić, V. *Elektrane*, AGM, Beograd, 2014.
- [11] Hagan, M.T., Demuth, H.B., Bale, M. *Neural Network Design*, PWS Pub., Boston, USA, 1996.
- [12] Karayiannis, N.B., Venetsanopoulos, A.N. *Artificial neural networks: learning algorithms, performance evaluation, and applications*, Springer, USA, 1993.

AUTORI/AUTHORS

Stefan Čubonović - asistent, Fakultet tehničkih nauka u Čačku, stefan.cubonovic@ftn.kg.ac.rs, ORCID [0000-0002-0240-5349](https://orcid.org/0000-0002-0240-5349)

Aleksandar Ranković - redovni profesor, Fakultet tehničkih nauka u Čačku, aleksandar.rankovic@gmail.com, ORCID [0000-0002-7205-9584](https://orcid.org/0000-0002-7205-9584)

Marko Krstić, Akcionarsko društvo Elektroprivreda Srbije, marko.krstic996@gmail.com, ORCID [0009-0004-4706-405X](https://orcid.org/0009-0004-4706-405X)

The Application of Artificial Neural Networks for Predicting the Power Output of a Hydroelectric Power Plant

Abstract – The research paper analysed two types of artificial neural networks (ANN) for predicting the power output of a hydroelectric power plant. The first type is the feedforward artificial neural network (FF-ANN), while the second type is the recurrent neural network (RNN). Authors thoroughly analysed the steps taken in the process of implementing neural networks for this purpose, from data collection and preparation to training, evaluation, and results analysis. The input data includes net head, water flow through the turbine, upper water level, lower water level, and the temperature of the inlet cooling water. Based on the correlation coefficient of individual variables from the input layer with the output power, new ANN implementations were conducted. The results obtained from these variations were systematically analysed to achieve precise modelling, focusing on dynamic changes in water flow through the turbine.

Index Terms – Artificial neural network, FF-ANN, RNN, Hydroelectric power plant, Power output