

Predviđanje proizvodnje termoelektrane pomoću neuralnih mreža

Neural Networks Modelling for Thermal Plants Production Planning

Sonja Knežević, Mileta Žarković

Elektrotehnički fakultet Univerziteta u Beogradu

Rezime - Uz napredak elektroenergetskog sistema raste i njegova složenost, a samim tim i sve veća potreba za dobrom organizacijom proizvodnje i informacijama koje bi pomogle u planiranju. Kako su termoelektrane zadužene za pokriće baznog opterećenja predikcija proizvodnje termoelektrana se može znatno iskoristiti. Ovaj rad predstavlja upotrebu veštačkih neuralnih mreža za predikciju proizvodnje energije iz termoelektrana. Podaci koji su korišćeni za treniranje veštačke neuralne mreže su merenja proizvodnje energije iz termoelektrana u elektroenergetskom sistemu Srbije. Obučena neuralna mreža može da se koristi za predikciju proizvodnje na godišnjem nivou ili kraćim višednevnim ili dnevnim nivoima.

Ključne reči - veštačke neuralne mreže, modelovanje, predikcija proizvodnje, termoelektrane

Abstract - With the power systems progress, its complexity grows and there is a greater need for good production organization and the need for information that would help in power system planning. As thermal power plants are responsible for covering the base load, the prediction of its production can be used significantly for good power system organization. This paper represents the use of artificial neural networks for the prediction of thermal plants power production. The data used for neural networks training are measurements of thermal power plant production in power systems of Serbia. Trained neural network can be used for prediction of production on yearly basis or for shorter, hourly or daily prediction.

Index Terms - Artificial neural networks, Modelling, Production prediction, Thermal power plants

I UVOD

Za pravilno funkcionisanje društva potrebne su značajne količine električne energije, a sa razvojem i napretkom zahtevi za električnom energijom rastu. Kako bi se potražnja za električnom energijom zadovoljila elektrane moraju imati solidne sposobnosti. Najvažniji faktor je, pri zadovoljavanju potražnje za energijom, održati obećani nivo pouzdanosti i bezbednosti. Zbog svoje operativnosti i mogućnosti odziva na zahteve, za održavanje konstantnog opterećenja koriste se termoelektrane. Kako termoelektrane treba da pokriju bazno opterećenje sistema do njih moraju doći informacije neophodne kako bi se zahtevana snaga isporučila. Potrošnja električne energije je zavisna od mnogih socijalnih i ekonomskih faktora. Sve ove zavisnosti se

moraju uzeti u obzir pri planiranju rada sistema. Pošto u satnoj potražnji za električnom energijom postoji određena logičnost ponavljanja bilo bi korisno planiranje proizvodnje za duži period. Na osnovu planiranja proizvodnje termoelektrane može se odrediti i emisija CO₂ u budućnosti i shodno tome mere koje se trebaju preduzeti za smanjenje njegove količine [1].

U termoelektranama obično se koriste termodinamičke metode za analiziranje sistema. Ovakvi proračuni obrađuju veliki broj nelinearnih problema uz prepostavke parametara i određenih vrednosti, komplikovani su i često im je potrebno značajno vreme kako bi se izvršili [2].

Problemi ovakvog tipa sa velikim brojem ulaza i izlaza su savršeni za primenu metoda mašinskog učenja. Kako iz prethodnih godina postoji znatna baza merenja ona se može primeniti za obrađivanje algoritama koji bi predviđali potrebe za proizvodnjom u budućem vremenskom periodu. Upotrebom veštačkih neuralnih mreža ovakvi problemi se mogu rešavati efikasno suočenjem na trenirane mreže koja se može stalno nadograđivati dodavanjem novih podataka dobijenih trenutnim i budućim merenjima.

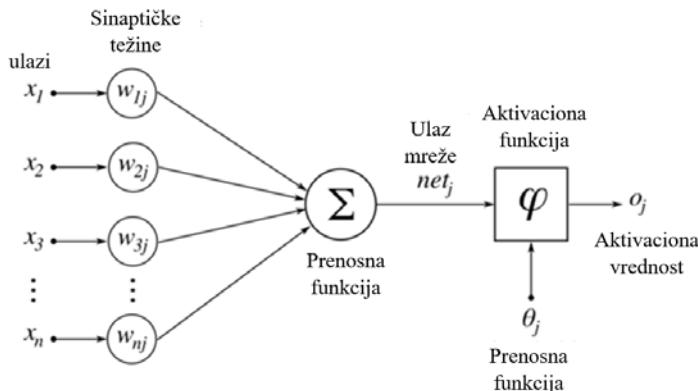
Ovaj rad predstavlja model neuralne mreže koji rešava problem predviđanja proizvodnje termoelektrane i emisije CO₂ na osnovu ulaznih podataka kao što su godišnje doba, doba dana, sat i dnevna temperatura pošto na ponašanje potrošača direktno utiču ovi parametri. Takođe je prikazana mogućnost nadogradnje neuralne mreže kako bi njene predikcije imale što veću tačnost. Ovakav model može biti korišćen za predikciju proizvodnje na godišnjem nivou ili kraćim vremenskim periodima koji mogu biti dan ili više dana radi lakše mogućnosti organizacije rada termoelektrane. Objasnjenja je konstrukcija neuralne mreže, konkretna baza podataka koja se koristila i izmene koje povećavaju stepen tačnosti predikcije. Kompletan model veštačke neuralne mreže je urađen u softverskom alatu MATLAB.

II VEŠTAČKE NEURALNE MREŽE

Veštačke neuralne mreže (Artificial Neural Network - ANN) su grana mašinskog učenja koja je srž hijerarhijskog ili dubokog učenja baziranom na veštačkoj inteligenciji. Njihova logika i sam nastanak su bazirani na imitaciji ponašanja neurona u čovekovom mozgu [3]. Veštačke neuralne mreže se sastoje od velikog broja međusobno gusto povezanih procesorskih elemenata (neurona) koji su organizovani po određenim arhitekturama. Pokazuju

informaciono procesiranje koje ima osobinu učenja i generalizacije na osnovu podataka kojima se obučavaju. Primjenjiva je na problemima koji nemaju jasno definisano funkciju povezanosti ulaznih i izlaznih podataka [4].

U ovom radu je posmatrana kako se veštačke neuralne mreže ponašaju u primeni na nadgledanom mašinskom učenju. U ovom tipu učenja izlaz y je već poznat i postoji mapiranje ulaza x sa izlazom y . Da bi se kreirao model, mašina se napaja velikim brojem ulaznih podataka za koje su izlazi poznati, kako bi se neuralna mreža obučila. Veliki broj podataka pomaže u povećanju nivoa tačnosti mreže, koja bi posle obuke napajana novim ulaznim podacima mogla da predviđa izlazne vrednosti [5].



Slika 1. Matematički model neurona neuralne mreže

Na slici 1 je prikazan matematički model neurona neuralne mreže. Svaki neuron ima svoje ulazne podatke sa kojima je povezan preko sinapsi. Sa x_i , gde je $i=1\dots n$, su prikazani ulazi koji mogu biti novi, neobrađeni ulazni podaci ili podaci koji se prosleđuju iz drugog neurona. Snaga veze između neurona i pojedinih ulaznih podataka je definisana sinaptičkim težinama. Ulazni podaci pomnoženi sa svojom sinaptičkom težinom ulaze u funkciju prenosa. Rezultat funkcije prenosa se poredi sa graničnom vrednošću. Na osnovu njihovog odnosa pokreće se aktivaciona funkcija koja daje rezultat 1 ako je vrednost funkcije prenosa veća od granične vrednosti i 0 u suprotnom. Ove vrednosti, 1 ili 0, su konačni izlaz neurona. Aktivaciona funkcija može biti linear, sigmoidalna, tangens-hiperbolička, relu i cureći relu. Najčešće se koristi sigmoidna aktivaciona funkcija [6].

Vrste aktivacionih funkcija:

1. Sigmoidna:

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

2. Tangens-hiperbolička:

$$f(\text{net}) = \tanh(\text{net}) \quad (2)$$

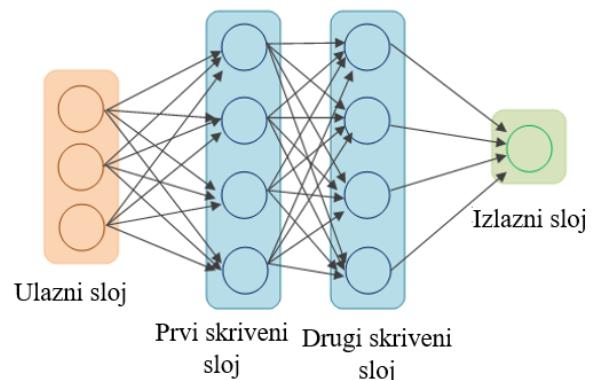
3. Relu:

$$f(\text{net}) = \max(0, \text{net}) \quad (3)$$

4. Cureći relu:

$$f(\text{net}) = \max(0.01\text{net}, \text{net}) \quad (4)$$

Od jednog neurona formira se sloj neurona, a od više slojeva čitava mreža njih. Jedan sloj čine neuroni formirani od istih ulaznih podataka, ali svaki sa svojom težinskim parametrima. Ovde će biti objašnjena *feedforward* neuralna mreža koja se sastoji od ulaznog sloja, skrivenih slojeva i izlaznog sloja koji su prikazani na slici 2. Ulazni sloj prima podatke dovedene neuralnoj mreži. Skriveni slojevi obrađuju podatke koje su dobili iz prethodnog sloja i njihov izlaz je ulaz za sledeći sloj neurona. Poslednji sloj u neuralnoj mreži je izlazni sloj i on treba da formira predikciju na osnovu podataka koji su mu dovedeni [7].



Slika 2. Matematički model neurona veštačke neuralne mreže

Kako bi neuralna mreža dala adekvatne izlaze sistema ona mora biti trenirana sa velikim brojem podataka koji se sastoje od ulaza sa svojim poznatim izlaznim vrednostima. Ovim se definiše njihova povezanost. Tačnost mreže se može povećati dodatnim podešavanjem broja skrivenih slojeva i broja neurona u skrivenim slojevima

Treniranje i testiranje neuralne mreže se vrši kroz tri faze. Ukoliko postoji dovoljno veliki broj podataka, u prvoj fazi se ulazna baza podataka podeli na obučavajući skup koji je 70% baze, testirajući skup koji je 15% baze i skup koji služi za validaciju i čini takođe 15% baze. Na validacionim podacima se uče najbolji parametri kao što su arhitektura mreže, tipovi aktivacionih funkcija, parametar regularizacije, optimalan trenutak za kraj obučavanja, i slično. Ukoliko broj podataka nije dovoljan da se podeli na tri skupa, deli se na dva, obučavajući skup koji je 70% baze i testirajući skup koji je 15% baze. Ovi skupovi se forme nasumičnim izborom podataka kako se ne bi desile slučajne klasifikacije. Podaci se zatim normalizuju kako ne bi došlo do poređenja vrednosti koje su u različitim kategorijama.

Tačnost mreže se procenjuje kroz vrednost greške *MAPE* (*Mean Average Percentage Error*). Ukoliko je ona u prihvatljivim granicama za mrežu se može reći da će dobro proceniti izlaze za sledeći skup ulaznih podataka. *MAPE* se računa koristeći sledeći izraz:

$$\text{MAPE}(x, y) = \text{MPE}(x, y) = \frac{\sum_{i=1}^N |y_i - x_i|}{x_i} \cdot 100\% \quad (5)$$

gde su N veličina dela baze podataka definisanog za testiranje, x_i ulazni podaci, a y_i predviđane vrednosti za ulaze x_i .

III PREDIKCIJA PROIZVODNJE TERMOELEKTRANA

Proizvodnja termoelektrana je zavisna od velikog broja faktora koji utiču na potražnju za energijom i koji se moraju uzeti u obzir. Predikcijom proizvodnje za naredni dan moglo bi se predviđati i stanje u čitavom sistemu kao i zahtevi koje termoelektrane treba da ispune. Na osnovu predviđanja potrošnje može se odrediti i moguća emisija štetnih gasova za budući period. Ovo ima značaj u planiranju funkcionisanja sistema kao i proceni zagađenja na čije smanjenje bi se moglo uticati.

U ovom radu predviđanje potrošnje termoelektrane je izvršeno za teritoriju Republike Srbije. Baza podataka se sastoji iz ulaznih i izlaznih podataka. Izlazni podaci su oni čija se predikcija želi, i u ovoj simulaciji to je proizvodnja termoelektrana. Ulagani podaci za bazu podataka su sledeći:

- Godišnje doba** - potrošnja električne energije se menja u zavisnosti od doba godine (da li je grejna sezona, da li je topao letnji period,...) pa se zakљučuje ponovljivost u sličnim dobima godine;
- Doba dana** - za doba dana se razlikuje podatak da li je dan ili noć;
- Sat u danu** - sa satom dana primećuje se promena potrošnje energije u zavisnosti od toga da li je period dana kada su ljudi u kućama i koje potrebe u tom trenu imaju;
- Prosečna dnevna temperatura** - temperatura ima značajan uticaj na potrošnju kao i na proizvodnju električne energije.

IV REZULTATI SIMULACIJA

Prvobitna simulacija imala je kao ulazne parametre četiri kolone definisane u poglavlju 3 koju su spoljašnji ulazi: godišnje doba, doba dana, sat u danu i temperaturom. Proračunom ovakvog tipa

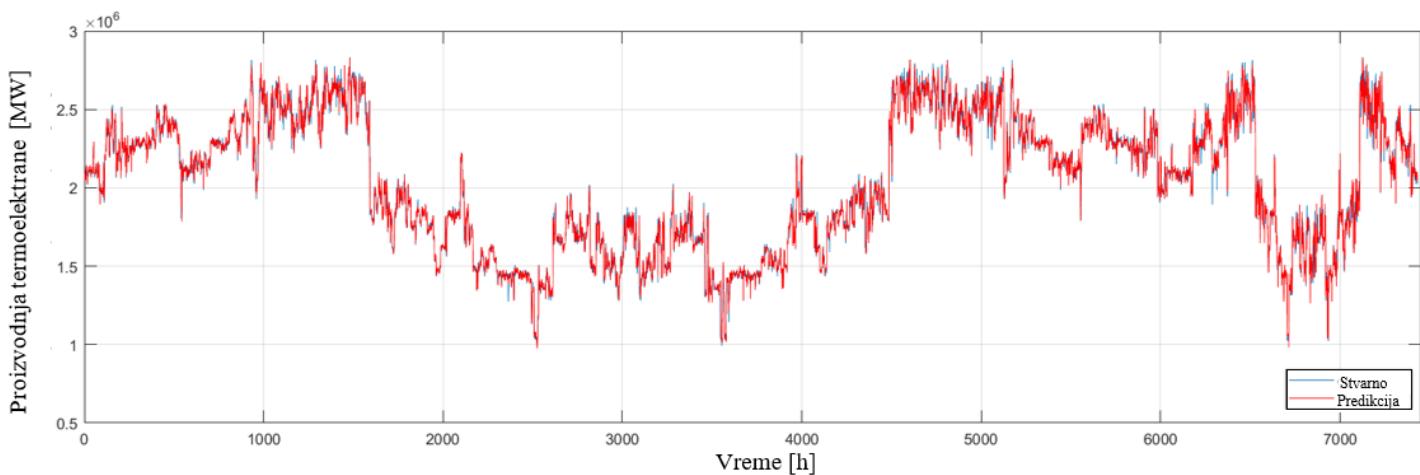
dobila se greška predikcije MAPE veličine reda 8%. Ovakva greška u radu neuralnih mreža nije drastična, ali izmenom baze podataka postoji mogućnost da se ona umanji što je uvek poželjno jer su potrebne što tačnije predikcije. Ideja je da se proširi broj podataka koji mreža obrađuje tako što se dodaje još jedan set ulaznih parametara.

Izmenom u kodu pri formiraju baze podataka uvršten je izlaz proizvodnje prethodnog dana, kao ulazni podatak za predikciju sledećeg dana. Tako se zapravo uvažava sličnost među danima i proširuje količina ulaznih podataka na kojima se trenira mreža. Rezultati predikcije ovakve neuralne mreže su daleko prihvatljiviji. Pri predikciji proizvodnje u ovoj neuralnoj mreži greška MAPE iznosi 1,388% što je sasvim zanemarljivo odstupanje od stvarnih vrednosti.

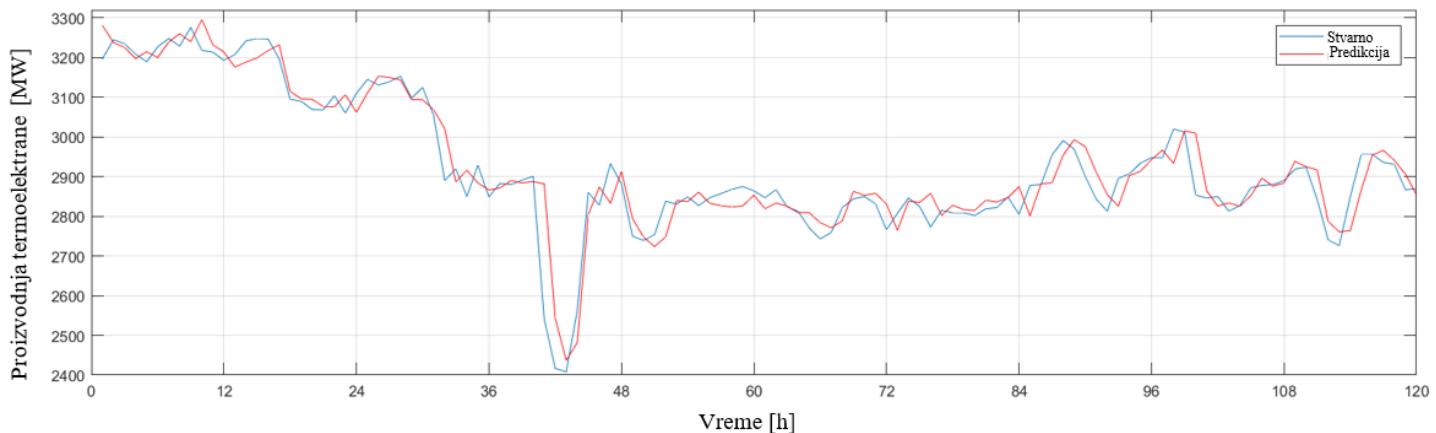
Tabela 1. Vrednosti grešaka MAPE za različito oformljene baze

Greška MAPE	Baza podataka sa 4 vrsta ulaznih podataka	Baza podataka sa 5 vrsta ulaznih podataka
MAPEt [%] (trenirajućeg)	8,880%	1,388%
MAPEo [%] (obučavajućeg)	8,215%	1,368%

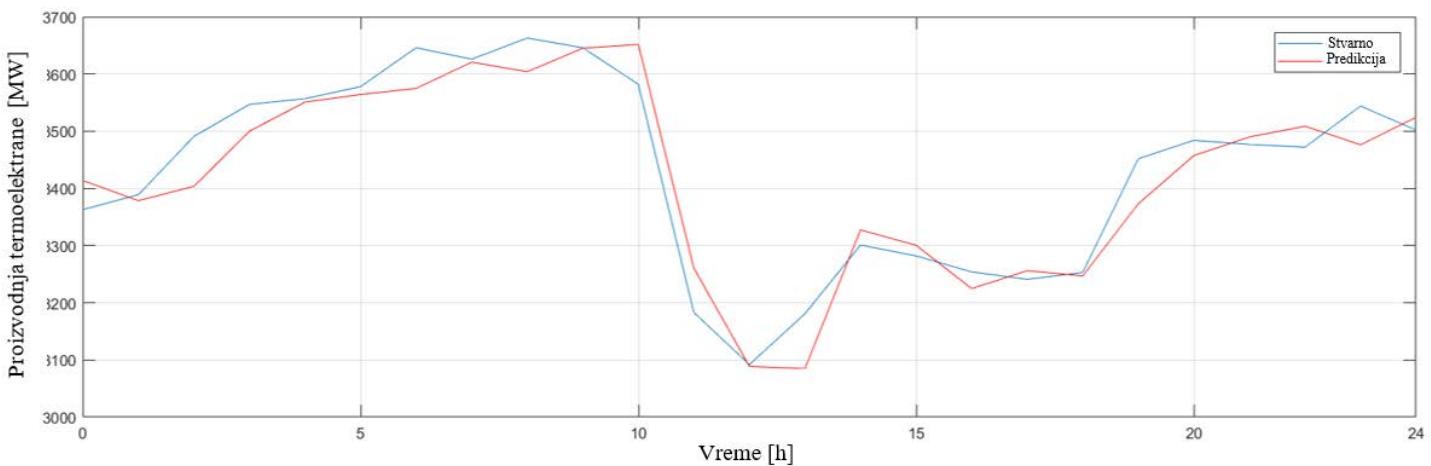
Na grafiku sa slike 3 je prikazano odstupanje stvarnih vrednosti izlaza i onih koji su nastali kao predikcija neuralne mreže za čitavu godinu. Na slici 4 je dat prikaz predikcije proizvodnje termoelektrane u nasumičnih pet dana. Ovakav prikaz je pregledniji kako bi se zaista videla odstupanja između krive koja predstavlja stvarne vrednosti (plava) i krive predikcije nastale iz rada neuralne mreže (crvena). Na grafiku na slici 5 je prikazana predikcija i stvarna vrednost za jedan nasumično izabran dan.



Slika 3. Predikcija proizvodnje termoelektrane na godišnjem nivou



Slika 4. Predikcija proizvodnje termoelektrane za pet dana



Slika 5. Predikcija proizvodnje termoelektrane za 24 sata

IV ZAKLJUČAK

Ovaj rad opisuje modelovanje neuralne mreže za predikciju proizvodnje termoelektrana. Uz dovoljnu količinu podataka za treniranje mreže i zadovoljavajuće izabranu strukturu može se definisati neuralna mreža koja definiše predikcije proizvodnje koja u zanemarujućim vrednostima odstupa od stvarnih. Greške se mogu dodatno smanjiti proširivanjem baze podataka i njenom adekvatnom obradom.

Ovakve predikcije koje mogu da se forme na višednevnom nivou su značajne za planiranje rada termoelektrane i mogu uticati na poboljšanje njihovog iskorišćenja. Uz dovoljnu količinu podataka za treniranje neuralne mreže ovakvi modeli mogu biti korišćeni za predikciju teže predvidivih izvora energije kao i za predikciju emisija CO₂ čijim bi se poznavanjem moglo uticati na njihovo smanjenje.

LITERATURA/REFERENCES

- [1] Ahamed Saleel, C. Forecasting the energy output from a combined cycle thermal power plant using deep learning models, Case Studies in Thermal

Engineering, Vol. 28, 101693, 2021.

<https://doi.org/10.1016/j.csite.2021.101693>

- [2] Kesgin, U., Heperkan, H. Simulation of thermodynamic systems using soft computing techniques, International Journal of Energy Research, Vol. 29, pp. 581-611, 2005. <https://doi.org/10.1002/er.1095>
- [3] Kotur, D., Žarković, M. Neural Network Models for Electricity Prices and Loads Short and Long-Term Prediction, in Proc. 4th International Symposium on Environmental Friendly Energies and Applications (EFEA), Belgrade, Serbia, pp. 1-5, 14-16 September, 2016. <https://doi.org/10.1109/EFEA.2016.7748787>
- [4] Rojas, R. *Neural Network - A Systematic Introduction*, Springer, 1996.
- [5] Zhang, Y. (ed.) *New Advances in Machine learning*, IntechOpen 2010. <https://doi.org/10.5772/225>
- [6] Ongsakul, W., Dieu Ngoc, V. *Artificial intelligence in power system optimization*, CRC Press, Taylor & Francis, 2013. <https://doi.org/10.1201/b14906>
- [7] Gurney, K. *An Brief Introduction to Neural Networks*, UCL Press 1997.

AUTOR/AUTHORS

msr Sonja Knežević, Univerzitet u Beogradu, Elektrotehnički fakultet, sonjaknezevic98@gmail.com, ORCID [0000-0002-1886-243X](https://orcid.org/0000-0002-1886-243X)
dr Mileta Žarković - vanredni prof., Univerzitet u Beogradu, Elektrotehnički fakultet, mileta@etf.bg.ac.rs, ORCID [0000-0001-5855-6595](https://orcid.org/0000-0001-5855-6595)