

Primena veštačkih neuralnih mreža za predikciju generisane električne energije vetrogeneratora

M. Majstorović, I. Nikolić, V. Nikolić

Sadržaj — U ovom radu opisana je primena feed forward neuralnih mreža za predikciju električne energije koju proizvodi vetrogenerator. Radi lakšeg kalkulisanja profita, kao i zbog stabilnosti elektroenergetskog sistema, veoma je važno raspolagati dovoljno tačnom predikcijom generisane električne energije u toku dužeg vremenskog perioda. Imajući ovo u vidu, cilj je bio smanjenje srednje greške predikcije što je više moguće. Neuralna mreža opisana u ovom radu je višeslojna feed forward neuralna mreža. Svi eksperimenti i simulacije izvršeni su u programskom paketu Matlab.

Ključne reči — Neuralne mreže, predikcija, električna energija, vetrogenerator

I. UVOD

Energija vetra danas predstavlja najiskorišćeniji resurs iz grupe obnovljivih izvora energije. Međutim, i pored tehnološkog napretka u pogledu poboljšanja elektromehaničkih karakteristika vetrogeneratora, glavni problem u proizvodnji električne energije ovim putem predstavlja nemogućnost egzaktnog predviđanja proizvedene električne energije. Upravo se za takvu predikciju koristi sprega između meteorološkog modela lokacije na kojoj je postavljen vetrogenerator i neuralne mreže koja vrši predikciju generisane električne energije. Cilj ovog rada jeste predstavljanje dizajna i razvoja feed forward neuralne mreže u svrhu predikcije generisane električne energije vetrogeneratora sa zadovoljavajućom tačnošću. Osnovna prednost upotrebe neuralnih mreža u ovom slučaju ogleda se u činjenici da nije neophodno poznavati tačne matematičke modele kako samog vetrogeneratora, tako i meteoroloških uslova. Mnogi radovi su se do sad bavili predikcijom snage vetrogeneratora pomoću neuralnih mreža, kao što je rad [1], koristeći uglavnom snimljene meteorološke podatke. Iako su se ANFIS sistemi pokazali kao uspešni u rešavanju problema predikcije [2], u ovom radu je primenjena feed forward neuralna mreža kako bi se obezbedila jednostavnost sistema za predikciju. Za razliku

od [1] gde su kao ulazni podaci korišćeni upravo snimljeni meteorološki podaci, u ovom radu se koriste podaci prognozirani od strane meteorološkog modela. Iako manje precizni, (što zavisi od kvaliteta upotrebljenog meteorološkog modela), ovi rezultati su mnogo dostupniji, odnosno ne zahtevaju dugotrajna snimanja. Neuralna mreža opisana u ovom radu obučavana je na ulaznim podacima dobijenim iz meteorološkog modela, ali je kao izlazni podatak korišćena izmerena vrednost izlazne snage vetrogeneratora. Na taj način, uneta je dodatna greška, koja zavisi od greške meteorološkog modela. Tačnost meteorološkog modela može se predstaviti pomoću srednje apsolutne greške predikcije (Mean Absolute Percentage Error – MAPE):

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{abs(y_i - x_i)}{y_i} \cdot 100\%.$$

II. ANALIZA I PODELA PODATAKA

Skup podataka korišćen u ovom radu sastoji se od sedam fizičkih veličina (šest ulaza i jedan izlaz). Kao što je navedeno, ulazi su dobijeni iz meteorološkog modela, dok izlaz predstavlja snimljeni izlaz procesa, odnosno stvarnu izlaznu električnu snagu vetrogeneratora:

- *friction_velocity* – trenje,
- *DTV* – gradijent temperature,
- *speed_first_level* – brzina vetra na visini od 70 m,
- *dir* – smer vetra [0°, 180°],
- *dens* – gustina vazduha,
- *speed10m* – brzina vetra na visini od 10 m,
- *power* – izlazna električna snaga vetrogeneratora.

Period odabiranja za date podatke iznosi $T_s = 1h$.

Bitno je još jednom naglasiti da podaci korišćeni u ovom radu nisu rezultat merenja već prognoze zasnovane na približnom matematičkom modelu meteoroloških procesa za datu geografsku oblast. Jedini izmereni podatak je generisana električna energija.

Za potrebe obučavanja, podaci su podeljeni na dva podskupa – deo za obučavanje i deo za testiranje. Vremenski interval na koji se odnose prikupljeni podaci je relativno dug


M. Majstorović, Saobraćajni institut CIP, Nemanjina 6, 11000 Beograd, Srbija (telefon 381-64-3076422, e-mail: majstorovicmladen@gmail.com).

I. Nikolić (autor za kontakte), Institut "Mihajlo Pupin", Volgina 15, 11060 Beograd, Srbija, (telefon 381-63-601437, e-mail: ivan.nikolic81@gmail.com)


V. Nikolić, Weather2Umbrella, Marina Držića 5/13, 26000 Pančevo, (telefon 381-64-6480360, e-mail: dovlan@gmail.com).

(oko tri meseca), čime su obuhvaćene značajne varijacije vremenskih uslova (pre svega brzine i smera vetra) na posmatranom području. Zbog toga je podskup podataka za testiranje formiran izvlačenjem svakog trećeg odbirka iz polaznog skupa. Rezultat su dva podskupa – podskup za obučavanje koji sadrži dve trećine podataka iz polaznog skupa i podskup za testiranje koga čini jedna trećina polaznih podataka. Ovako dobijeni podskupovi pokrivaju sve sezonske varijacije do kojih može doći na datom intervalu podataka. Podaci iz ovih podskupova su zatim normalizovani u intervalu $[0, 1]$. Normalizacija je odabrana jer su sami podaci različite fizičke veličine, čije se vrednosti razlikuju i za nekoliko redova veličina. Neuralna mreža obučena na ovakvim podacima nesumnjivo će imati drastične razlike u težinskim koeficijentima, naročito u ulaznom sloju. Ovako nastala na taj način, prouzrokovana prvenstveno zaokruživanjem brojeva u računaru, može imati značajne vrednosti.

Skupovi podataka za obučavanje i testiranje prikazani su grafički na slici 1 i 2. Skup podataka za obučavanje sastoji se od 639 odbiraka dok se skup podataka za testiranje sastoji iz 182 odbirka.




Slika 1. Skup podataka za obučavanje



Slika 2. Skup podataka za testiranje

Na slici 1 i 2 jasno se vidi da je u određenim intervalima izlazna snaga vetrogeneratora u zasićenju. To je posledica elektromehaničkih karakteristika samog vetrogeneratora. Na slici 3 je prikazana “kriva snage” datog vetrogeneratora, na kojoj se vidi zavisnost izlazne snage od brzine vetra. Ovako prikazana karakteristika je samo aproksimacija. U stvarnosti nije moguće dati ovako jednoznačnu vezu, zbog uticaja ostalih ulaznih veličina (vazdušni pritisak, temperatura ...) na vrednost izlazne promenljive. Međutim, u kvalitativnoj analizi koju nam kriva snage omogućava, jasno se vidi da se skup

svih mogućih brzina vetra može podeliti na tri oblasti. Prva oblast, do neke vrednosti $V_1 \approx 10m/s$, predstavlja gotovo linearnu zavisnost izlazne snage od brzine vetra. U oblasti iznad V_1 ne dolazi do povećanja izlazne snage sa brzinom vetra, što je posledica ograničenja brzine samog rotora turbine. Takođe, u oblasti iznad $V_{crit} \approx 18m/s$ dolazi do dejstva ugrađene zaštite od preopterećenja, koja koči rotor, te ga na taj način štiti od mehaničkih oštećenja do kojih bi moglo doći pri velikim brzinama. U toj oblasti, izlazna snaga je smanjena u odnosu na maksimalnu. Ove dve oblasti visoko nelinearne zavisnosti su, pored činjenice da su ulazni podaci generisani meteorološkim modelom, glavni izvor greške izlaza neuralne mreže.



Slika 3. Kriva snage vetrogeneratora

U cilju postizanja boljih rezultata, ulazni vektori $speed_first_level$ i $speed10$ su razloženi na sastavne komponente duž x i y osa koordinatnog sistema, uz pomoć sledećih jednačina:

$$speed_first_level_x = speed_first_level \cdot \cos(dir),$$

$$speed_first_level_y = speed_first_level \cdot \sin(dir).$$

$$speed10m_x = speed10m \cdot \cos(dir),$$


$$speed10m_y = speed10m \cdot \sin(dir).$$

Na taj način ulaz dir postaje suvišan. Ovako obrađen skup podataka sastoji se iz sedam ulaznih i jednog izlaznog vektora.

III. NEURALNA MREŽA

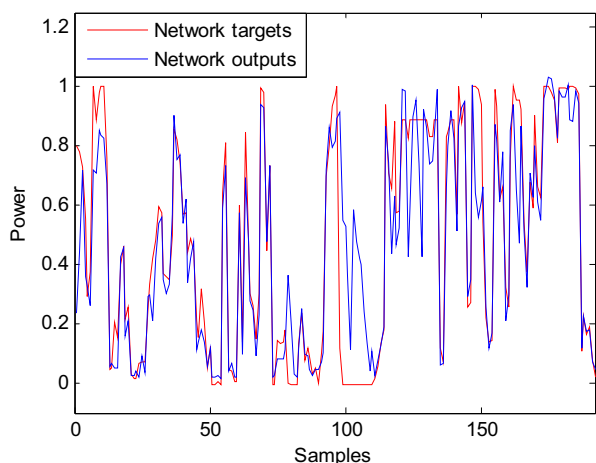
Prvi pokušaj razvoja neuralne mreže za dati problem predstavlja konvencionalni pristup po kojem je broj skrivenih slojeva neuralne mreže jednak broju njenih izlaza. U ovom slučaju neuralna mreža ima samo jedan skriveni sloj. Rezultati dobijeni upotrebom ovakve mreže prikazani su na slici 4. Ovaj pristup se nije pokazao preterano uspešno, zbog nemogućnosti neuralne mreže da adekvatno modeluje sistem. Na slici 4 može se uočiti ne samo odstupanje izlaza neuralne mreže od stvarnog izlaza procesa, nego i značajno probijanje granica intervala normalizacije $[0, 1]$.

Kao što je već napomenuto, osnovni problem u treniranju neuralne mreže predstavlja zasićenje izlaza, kao i zaštita od prekoračenja. Dakle, neophodno je da neuralna mreža poseduje dovoljan broj neurona kako bi bila u stanju da modeluje nelinearnosti, vodeći računa da pri tom ne dođe do preobučavanja same neuralne mreže.



Slika 4. Izlaz neuralne mreže sa jednim skrivenim slojem


Nešto bolji rezultati su dobijeni sa neuralnom mrežom koja se sastoji od pet slojeva. Iako poboljšani, rezultati još uvek nisu zadovoljavajući. Srednja apsolutna greška je i dalje značajna. Na slici 5 prikazan je izlaz neuralne mreže sa pet skrivenih slojeva.



Slika 5. Izlaz neuralne mreže sa pet skrivenih slojeva

Neuralna mreža koja je dala najbolje rezultate razvijena je u nizu pokušaja. Sama mreža se sastoji od šest slojeva, koji su međusobno spregnuti na specifičan način, kako je šematski prikazano na slici 6. Izlazni sloj, kao što je i očekivano, sastoji se iz samo jednog neurona, zbog toga što postoji samo jedan izlaz procesa. Peti, odnosno preposlednji sloj se takođe sastoji od jednog neurona, što se pokazalo kao efikasno sredstvo za smanjenje velikih odstupanja izlaza mreže od normalizacionog intervala. Na slici se vidi da su ulazi *Input6* i *Input7* povezani

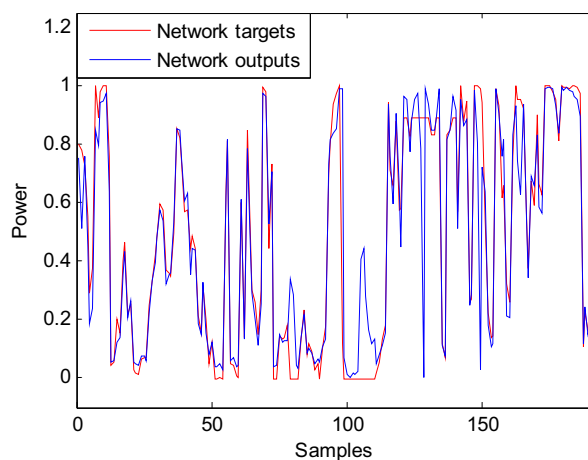
na ulaze svakog skrivenog sloja. Ti ulazi su *speed_first_level_x* i *speed_first_level_y*.



Slika 6. Šema neuralne mreže sa šest slojeva

Može se pretpostaviti da ti ulazi najviše utiču na izlaz neuralne mreže. Takođe su uvedene neke veze između samih slojeva – izlaz prvog sloja je prosleđen na ulaze trećeg i četvrtog sloja a izlaz drugog sloja je prosleđen na ulaz četvrtog sloja.

Kao prvi korak, da bi se postigli bolji rezultati, svi slojevi su međusobno povezani. Ovaj pristup dao je bolje rezultate, ali zbog drastičnog povećanja težinskih koeficijenata, vreme potrebno za obučavanje se značajno povećalo. Sledeći korak predstavlja nasumično ukidanje nekih veza, i poređenje rezultata koje daje takva mreža sa prethodnom, sve dok nije dobijena mreža pojednostavljene strukture, istovremeno ne narušavajući performanse mreže odnosno kvalitet predikcije.




Slika 7. Izlaz neuralne mreže sa šest skrivenih slojeva

Izlazni rezultati neuralne mreže su prikazan na slici 7. Na slici se može videti da su performanse mreže poboljšane u odnosu na prethodnu, srednja apsolutna greška je smanjena. Na slici 9 se vidi da srednja apsolutna greška predikcije iznosi približno: $MAPE \approx 5.847\%$. Takođe, svi odbirci izlaznog signala nalaze se unutar normalizacionog intervala, $[0, 1]$. To je između ostalog posledica korišćenja log-sigmoidalne funkcije (slika 8) kao aktivacione funkcije neurona koji se nalaze u prvih pet slojeva.

Odstupanja koja postoje i dalje su relativno velika u odnosu na stvarna merenja, naročito pri velikim brzinama vetra pri kojima je izlaz ograničen usled dejstva zaštite od

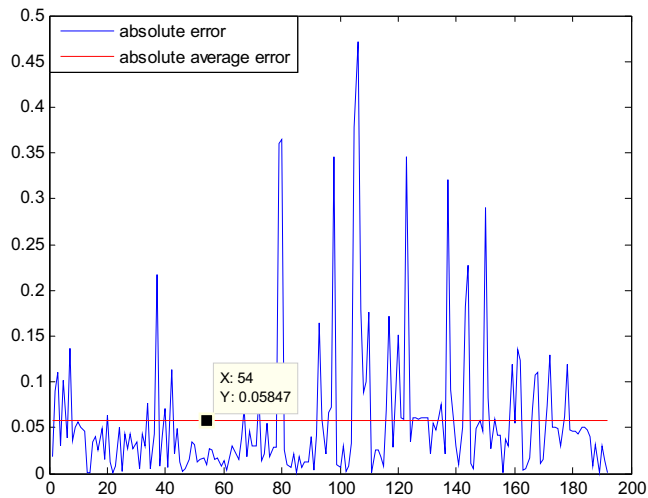
preopterećenja.



Slika 8. Log-sigmoidalna funkcija

Prema tome, neuralna mreža pokazuje najbolje rezultate pri brzinama vetra manjim od $V_1 \approx 10 \text{ m/s}$.

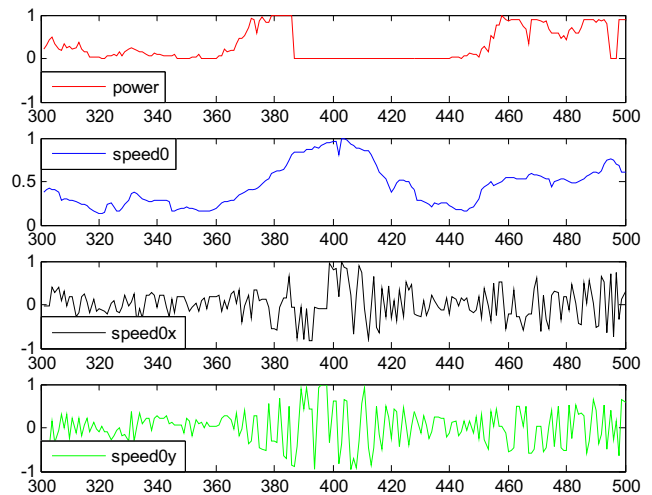
Kako se može zaključiti na slici 9, greška nije uniformno raspodeljena, već ima jako velike vrednosti u određenim tačkama.



Slika 9. Greška izlaza neuralne mreže sa šest skrivenih slojeva

Uzastopnim ponavljanjem procesa obučavanja neuralne mreže, primećeno ja da se velike vrednosti greške izlaza javljaju na približno istim mestima. Obzirom da ove vršne vrednosti značajno doprinose povećanju srednje apsolutne greške, sprovedena su detaljnija ispitivanja. Zaključeno je da je izvor ovakvih pikova nepreciznost korišćenog meteorološkog modela, odnosno rad sa nedovoljno tačnim ulaznim podacima generisanim od strane istog. Eliminisanje uticaja greške meteorološkog modela zahtevalo bi daleko veći skup ulaznih podataka.

Na slici 10 se može videti da postoji određeni vremenski period tokom kojeg je izlazna snaga vetrogeneratora jednaka nuli uprkos značajnim vrednostima brzine vetra. Razlozi za ovako neočekivano ponašanje mogu se pronaći u pomenutim nesavršenostima meteorološkog modela kao i nekim neregularnim stanjima samog vetrogeneratora (mehanička blokada, ispad generatora itd.).



Slika 10. Deo odbiraka ulaznih podataka

IV. ZAKLJUČAK

Eksploatacija energije vetra je najzastupljeniji vid dobijanja električne energije alternativnim putem. Predikcija generisane električne energije je od velike važnosti kako za proračun profitabilnosti tako i za stabilnost elektroenergetskog sistema. U ovom radu je pokazano da se korišćenjem feed forward neuralne mreže relativno jednostavne strukture mogu dobiti rezultati velike pouzdanosti. Iz predstavljenih rezultata može se doći do zaključka da postoje dva osnovna izvora greške koja se javlja pri ovakvoj predikciji. Prvi leži u činjenici da je greška izlaza neuralne mreže veća za velike vrednosti brzine vetra, naročito u slučajevima kada dejstvuje zaštita od preopterećenja. Razlog za to predstavlja relativno mala veličina neuralne mreže koja nije bila u stanju da dovoljno dobro modeluje nelinearnu zavisnost izlazne snage od ulaznih parametara. Pokušaji da se ovaj problem prevaziđe povećanjem kompleksnosti neuralne mreže su rezultovali njenim pretreniranjem (overfitting). Drugi značajni izvor greške je nesavršenost meteorološkog modela kako je već prethodno opisano. Uprkos ovim ograničenjima, utvrđeno je da se i pored inicijalne greške koju unosi meteorološki model pomoću relativno jednostavne neuralne mreže mogu dobiti dobri rezultati. U poređenju sa radom [3] koji koristi izmerene meteorološke podatke, može se smatrati da su rezultati predstavljeni u ovom radu zadovoljavajući. Uz precizniji meteorološki model moguća su dalja poboljšanja ostvarenih rezultata.

V. REFERENCE

- [1] *Using neural networks to estimate wind turbine power generation*, Shuhui Li; Wunsch, D.C.; O'Hair, E.A.;

Giesselmann, M.G.; Dept. of Electr. Eng., Texas Tech. Univ., Lubbock, TX , ISSN: 0885-8969

- [2] *Predikcija vremenskih serija korišćenjem modifikovane anfis arhitekture*, B. Jovanović, I. Reljin, B. Reljin, 2009.
- [3] *A Neuro-Fuzzy Synergism to Intelligent Systems*, Chin-Teng Lee and C. S. George Lee, Prentice Hall, 1996.
- [4] *Neural Networks and Learning Machines*, Simon Haykin, Prentice-Hall, 2009.
- [5] *Feedforward Neural Network Methodology*, T.L. Fine, Springer, 1999.
- [6] *Neural Smithing: Supervised Learning in Feedforward Artificial Neural Networks*, Reed, R.D., Marks, R.J, Cambridge, MA: The MIT Press, 1999.
- [7] *Time Series Prediction: Forecasting the Future and Understanding the Past*, Weigend, A.S. and Gershenfeld, N.A., Addison-Wesley, 1994.
- [8] *Neural Networks for Pattern Recognition*, Christopher M. Bishop, Oxford University Press, 1995.
- [9] *Neural Network Toolbox, For Use with Matlab®*, Howard Demuth, Mark Beale and Martin Hagan, The MathWorks, 2007.