



Primjena dubokog učenja za prognoziranje proizvodnje vjetroelektrana


Josip Đaković, mag.ing.

Fakultet elektrotehnike i računarstva
Sveučilište u Zagrebu

Uvod



- **Precizne prognoze proizvodnje OIE omogućuju:**
 - **Ekonomičnije vođenje EES-a**
 - Niži troškovi energije uravnotežnjenja, manji zahtjevi za regulacijskim rezervama i re-dispečiranjem elektrana itd.
 - **Pouzdaniji rad EES-a**
 - Prognoziranje velikih promjena proizvodnje (rampe snage) iz OIE pridonosi očuvanju stabilnosti EES-a.

Prognoziranje proizvodnje - pristupi



Primjena dubokog učenja za WPF

- Neuronske mreže (složeni matrični algoritmi) za prognoziranje vremenskih serija (sekvenci) – *sequence-to-sequence* problem
 - Rekurentne (RNN) mreže




$$\begin{aligned}
 i_t &= \sigma_g(W_i x_t + R_i h_{t-1} + b_i) \\
 f_t &= \sigma_g(W_f x_t + R_f h_{t-1} + b_f) \\
 \tilde{c}_t &= \sigma_c(W_g x_t + R_g h_{t-1} + b_g) \\
 o_t &= \sigma_g(W_o x_t + R_o h_{t-1} + b_o) \\
 \sigma_c(x) &= \tanh(x) \\
 \sigma_g(x) &= (1 + e^{-x})^{-1} \\
 h_t &= o_t \odot \sigma_c(c_t) \\
 c_t &= f_t \odot c_{t-1} + i_t \odot \tilde{c}_t
 \end{aligned}$$


Analiza ulaznih podataka (mjerena)

Primjeri za jednu lokaciju VE:


- Snaga na temelju brzine i smjera vjetra
- Ruža vjetrova sa srednjom brzinom vjetra
- Distribucija brzine vjetra na lokaciji (SCADA ostvarenja)
- Matrica korelacije parametara
 - auto-korelacija je na dijagonalni (tamno plavo)
 - snaga korelira jako pozitivno s brzinom vjetra
 - snaga korelira negativno s temperatom




Proizvodnja VE u odnosu na brzinu i smjer vjetra



Ruža vjetrova sa srednjom brzinom vjetra



Distribucija brzine vjetra na lokaciji VE



Matrica korelacije mjerjenih parametara

Prediktori proizvodnje VE

Meteorološke prognoze (NWP)

- ▶ Korišteni NWP je **Weather Research and Forecasting (WRF)**
- ▶ Prognostički model otvorenog koda, razvijan od strane mnogih znanstvenih ustanova od 1990. (NCAR, NOAA, AFWA ...)
- ▶ Pruža meteo prognoze do 72 sata unaprijed (4 puta dnevno – svakih 6 sati) za sve lokacije VE (npr. brzina i smjer vjetra, relativna vlažnost, temperatura, tlak)

Planovi raspoloživosti kapaciteta VE

- ▶ Operateri svake VE dostavljaju satni, dan-unaprijed plan raspoloživosti ukupnog kapaciteta VE prema HROTE-i, ukoliko planirani raspoloživi kapacitet nije maksimalan (remonti, kvarovi itd.)

Priprema ulaznih podataka



Dohvaćanje,
usrednjavanje na
isti vremenski
period, filtriranje
pogrešnih
vrijednosti (eng.
outlier)

Spajanje
podataka iz više
izvora prema
istim
vremenskim
trenucima

Razdvajanje
podataka na skup
za treniranje,
validaciju i
testiranje



Formiranje
ulaznih 3D polja
podataka za
trening,
validaciju i
testiranje

Treniranje modela DU



Testiranja modela i usporedba sa komercijalnim alatim WPPT 3 i AIOLOS


- **Testni period : 18.10.2020.-16.12.2020.**
- **236 prognostičkih sekvenci 60 sati unaprijed**




Razvoj prognostičke aplikacije

- **Razvijena na ZVNE-u**
- **Prognostički alat temeljen na modelima dubokog učenja**
- **Prognoza proizvodnje 24 VE u RH (72 sata unaprijed), 2 modela za svaku VE**
- **Trenutno u testnom pogonu u HOPS-u**

Sučelje aplikacije



Prediktori



Objavljeni radovi iz područja

- [1] J. Đaković and I. Kuzle, "Status i klasifikacija metoda za predviđanje proizvodnje električne energije iz vjetroelektrana," in 13. Symposium on Power System Management, Rovinj, Hrvatska, 2018.
- [2] J. Đaković, B. Franc, I. Kuzle i M. Jembrih, »Primjena metoda dubokog učenja na prognoziranje proizvodnje iz vjetroelektrana,« u 14. Simpozij o vođenju EES-a (Cigre), on-line, 2020.

Poslan na recenziju:

- [3] M. Zou, N. Holjevac, J. Đaković, I. Kuzle, R. Langella, V. Di Giorgio i S. Djokic, »Bayesian CNN-BiLSTM and Vine-GMCM Based Probabilistic,« IEEE PES Transactions on Sustainable Energy.

Hvala na pažnji

