

Josip Đaković¹
FER-ZVNE
josip.djakovic@fer.hr

Bojan Franc
FER-ZVNE
bojan.franc@fer.hr

Igor Kuzle
FER-ZVNE
igor.kuzle@fer.hr

Matija Jembrih
HOPS
matija.jembrih@hops.hr

PRIMJENA METODA DUBOKOG UČENJA NA PROGNOZIRANJE PROIZVODNJE IZ VJETROELEKTRANA

SAŽETAK

Trend povećane integracije vjetroelektrana u elektroenergetski sustav predstavlja izazov za operatore prijenosnog i distribucijskog sustava te operatora tržista električne energije. Varijabilnost proizvodnje električne energije iz vjetroelektrana povećava zahtjeve za fleksibilnošću koja je potrebna kako bi se osigurao pouzdan i stabilan rad elektroenergetskog sustava. Vođenje elektroenergetskog sustava s visokim udjelom obnovljivih izvora zahtijeva napredne metode prognoziranja proizvodnje i potrošnje kako bi se osigurao pouzdan i ekonomičan pogon sustava. U radu je prikazana primjena metoda dubokog učenja za prognozu proizvodnje iz vjetroelektrana. Modeli su trenirani na stvarnim mjeranjima i prognozama vjetra na lokacijama na kojima su instalirane vjetroelektrane u Hrvatskoj. Dodatno, prikazana je usporedba točnosti predloženih modela s trenutno korištenim prognostičkim alatima.

Ključne riječi: prognoziranje proizvodnje, duboko učenje, rekurentne neuronske mreže, vjetroelektrane

APPLICATION OF DEEP LEARNING METHODS TO WIND POWER FORECASTING

ABSTRACT

The trend of increased integration of wind farms into the electricity system is a challenge for transmission and distribution system operators and electricity market operators. The variability of electricity generation from wind farms increases the requirements for the flexibility needed to ensure reliable and stable operation of the power system. Operating a power system with a high share of renewables requires advanced production and consumption forecasting methods to ensure reliable and economical operation of the system. The paper presents the application of deep learning methods to the forecast of production from wind farms. The models are trained on actual wind measurements and forecasts in the areas of Croatian wind farms. Additionally, a comparison of the accuracy of the proposed models with the currently used forecasting tools is presented.

Key words: production forecasting, deep learning, recurrent neural networks, wind farms

¹ Stavovi izneseni u referatu su osobna mišljenja autora, nisu obvezujući za poduzeće/instituciju u kojoj je autor zaposlen te se ne moraju nužno podudarati sa službenim stavovima poduzeća / institucije.

1. UVOD

Proizvodnja energije iz obnovljivih izvora (OIE), od kojih najveći udio čini proizvodnja iz vjetroelektrana (VE), imat će sve značajniji utjecaj u ostvarivanju niskougljičnog razvoja energetskog sektora zbog kontinuiranog povećanja instaliranih kapaciteta OIE u elektroenergetskom sustavu (EES). Iako integracija vjetroelektrana donosi mnoge pogodnosti s ekološkog aspekta, nepredvidiva i promjenjiva narav proizvodnje iz VE predstavlja mnoge izazove za operatore EES-a (osiguranje odgovarajućih pomoćnih usluga, ekonomsko dispečiranje elektrana, dinamička stabilnost sustava), operatore tržišta električne energije, te za proizvođače i trgovce električnom energijom. Jedno od mogućih rješenja za navedene izazove je razvoj naprednih alata i metoda za pouzdano kratkoročno prognoziranje proizvodnje iz VE [1]. Vremenska skala prognoziranja može se, za praktične potrebe, podijeliti na kratkoročne (do 12 sati unaprijed) i dugoročne (do 72 sata unaprijed) prognoze [2], [3]. Kratkoročne prognoze mogu se koristiti za regulaciju sustava i vođenje unutardnevног tržišta električne energije, dok se dugoročna prognoziranja često koriste za planiranje vozognog reda elektrana i dan-unaprijed tržište električne energije [4]. U posljednjih nekoliko desetljeća količina raspoloživih podataka i računalne snage brzo je rasla, omogućavajući da se metode prognoziranja razviju od jednostavnih statističkih i fizičkih modela do značajno složenih statističkih modela koji uključuju koncepte strojnog učenja i novijeg dubokog učenja [5]. Navedene metode analize velikih skupova podataka (eng. big data analysis) bave se ogromnim skupovima složenih podataka koji nisu pogodni za obradu tradicionalnim algoritmima. Metode koje se temelje na posebnoj vrsti rekurentnih neuronskih mreža (engl. Recurrent Neural Network - RNN) s dugom kratkoročnom memorijom (eng. Long Short-Term Memory - LSTM) prepoznate su kao izuzetno uspješne u modeliranju dugoročnih ovisnosti meteoroloških varijabli i proizvodnje energije [6], [7], [8]. Razlog za to je činjenica da su mreže temeljene na LSTM-u dizajnirane za učenje ovisnosti među nizovima podataka. Vremenska prognoza tj. numeričko vremensko predviđanje (eng. Numerical Weather Prediction - NWP) kao najvažniji ulaz za prognozu proizvodnje VE, pruža vremenski obilježene sekvene predviđanja, pogodne za treniranje dubokih rekurzivnih neuronskih mreža.

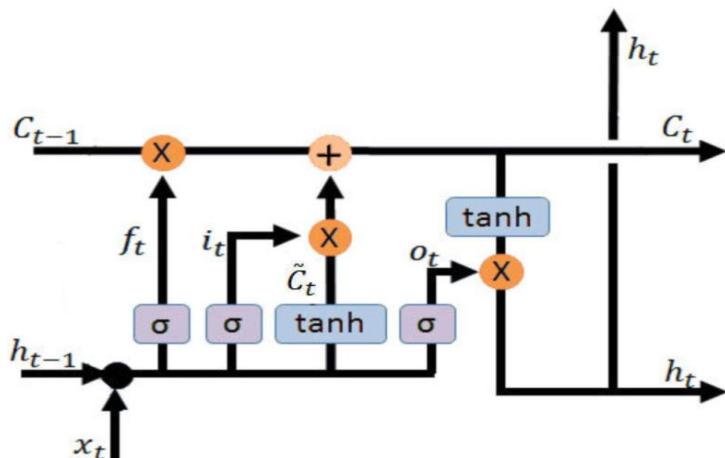
2. REKURZIVNE NEURONSKE MREŽE

Glavna karakteristika konvencionalnih neuronskih mreža, kao što su gusto povezane mreže i konvolucijske mreže, jest da nemaju memoriju. Svaki prikazani ulaz se obrađuje neovisno, bez određivanja ili usporedbe stanja između ulaza. S takvim mrežama, da bi se mogla obraditi sekvenca ili vremenska serija (eng. Time series), potrebno je cijelu sekvencu prikazati odjednom: pretvoriti je u jednu podatkovnu točku na ulazu u mrežu [9]. Takav tip neuronskih mreža naziva se *unaprijedne neuronske mreže* (eng. feedforward neural networks). Za razliku od navedenih, *rekurentne mreže* obrađuje nizove iteriranjem kroz elemente niza i održavanjem stanja koje sadrži informacije o do tad obrađenim podacima. Zapravo, RNN je vrsta neuronske mreže koja ima unutarnju petlju. Stanje RNN resetira se između obrade dvije različite, neovisne sekvene tako da se i dalje jedna sekvenca smatra jednom podatkovnom točkom: jednim ulazom u mrežu. Ono što se mijenja jest da se ta podatkovna točka više ne obrađuje u jednom koraku; mreža interno iterira nad elementima niza. Jednostavne (bazične) rekurentne mreže suočavaju se s problemom iščezavajućeg gradijenta prilikom treniranja dugačkih sekvenci pomoću dubokih mreža (mreže s većim brojem slojeva), što ih čini praktički neupotrebljivim. Riješenje navedenog problema predloženo je još 1997. (Hochreiter i Schmidhuber) u obliku mreža s dugotrajnom kratkoročnom memorijom, no praktična primjena ostvaruje se tek u posljednjih desetak godina. Procesiranje podataka u LSTM sloju prikazano je na slici 1. LSTM omogućava da informacija (skriveno stanje h_t), u bilo kojem trenutku t obrade ulazne sekvence (x_t), bude prebačena u dugoročnu memoriju (C_t), transportirana u kasniji vremenski trenutak te obrisana iz nje po potrebi. Navedene funkcije ostvaruju se pomoću posebnih *gate* funkcija (f_t, i_t, o_t). Ukratko, LSTM spremi informacije s početka sekvene za kasnije kako bi se izbjeglo iščezavanje gradijenta tijekom treninga.

2.1 Prognoziranje vremenskih sekvenci proizvodnje iz vjetroelektrana

Prognoziranje sekvenci razlikuje se od ostalih vrsta nadziranog strojnog učenja prema tome što se nameće zahtijev za očuvanje redoslijeda opažanja tijekom treniranja i testiranja modela. Osim numeričkih vremenskih sekvenci, rečenice u problemu prevodenja teksta predstavljaju drugi tip često korištenih sekvenici u nadziranom strojnem učenju. U razmatranom slučaju, sekvence proizvodnje radne snage iz VE su istovremeno i vremenske serije (nizovi), dobivene segmentiranjem kontinuirane dvogodišnje vremenske serije u djelomično vremenski preklapajuće sekvene². Iz navedenog razloga, u tekstu će se govoriti o vremenskim sekvencama.

² Sekvence proizvodnje je potrebno vremenski uskladiti s preklapajućim meteorološkim prognozama, koje se u razmatranom slučaju generiraju svakih 6 sati za sljedeća 72 sata, što znači da postoji višestruke prognoze za isti vremenski trenutak.

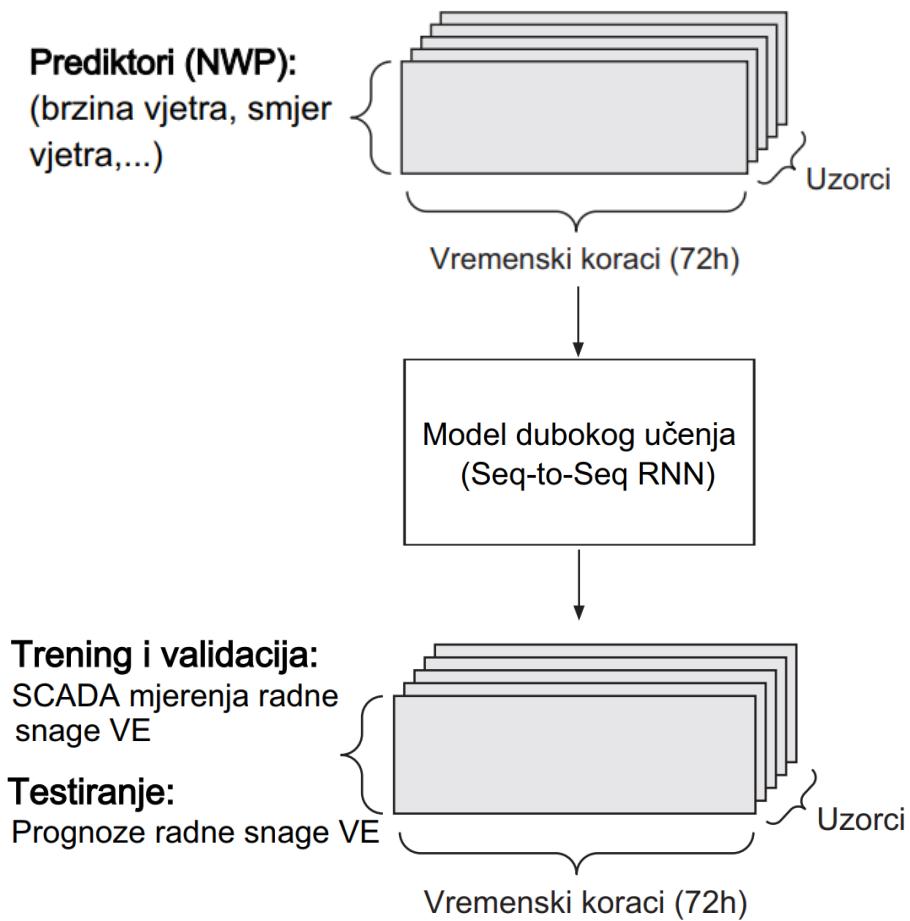


S1. 1.: Shema LSTM čelije

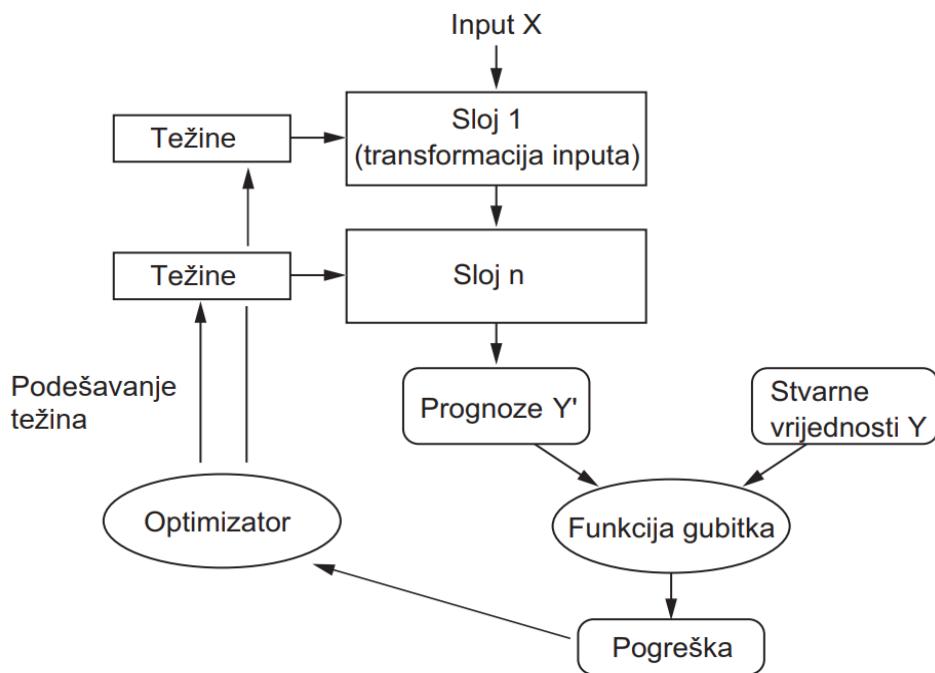
Općenito, problemi prognoziranja koji uključuju sekvencionalne podatke mogu se podijeliti u četiri skupine: 1) prognoza sljedeće vrijednosti sekvence; 2) klasifikacija sekvenci (prognoza klase prema ulaznoj sekvenci); 3) generacija sekvenci (npr. generiranje teksta); 4) prognoziranje sekvenci pomoću sekvenci (eng. Sequence-to-Sequence Prediction). Prema obliku dostupnih ulaznih podataka koji se mogu koristiti za prognozu proizvodnje iz vjetroelektrana (sekvencionalne prognoze atmosferskih prilika iz meteoroloških modela) i ostvarenja proizvodnje iz SCADA sustava, može se formulirati *Sequence-to-Sequence* problem: mapiranje sekvenci vremenskih prognoza (uglavnom brzina i smjer vjetra) na sekvence proizvodnje radne snage iz vjetroelektrana [10]. Slika 2 prikazuje način pripreme podataka za treniranje, validaciju i testiranje modela korištene u ovom radu. Prilikom treninga i validacije modela koriste se dostupni prediktori (u ovom slučaju brzina i smjer vjetra) koji se mapiraju na ostvarenu proizvodnju razmatranih VE. Razlika između treninga i validacije je u tome što se prilikom validacije ne podešavaju parametri neuronske mreže (težine). Prilikom testiranja, u model se ubacuju prediktori na kojima nije proveden trening te model daje prognozu na temelju 'naučenog' odnosa prognoze brzine i smjera vjetra te odgovarajuće radne snage vjetroelektrane.

2.2 Model dubokog učenja za sekvencionalne podatke

Temeljna struktorna jedinica u neuronskim mrežama za duboko učenje je sloj. Sloj je modul za obradu podataka koji uzima kao ulaz jedan ili više tenzora (podatkovnih jedinica) i koji daje jedan ili više tenzora na izlazu. Neki slojevi su bez unutarnjeg stanja, ali češće slojevi imaju stanje: težine sloja, jedan ili više tenzora podešenih metodama stohastičkog smanjenja gradijenta, u kojima je sadržana 'inteligencija' mreže. Sekvencionalni podaci obično se formiraju u 3D tenzore s dimenzijama (uzorci, vremenski koraci, značajke) i procesuiraju se pomoću rekurentnih slojeva kao što su LSTM i GRU (eng. Gated Recurrent Unit). Model dubokog učenja se konstruira 'slaganjem' kompatibilnih slojeva (kompatibilnost sloja ovisi o dimenziji ulaznih tenzora) u prikladnu konfiguraciju, ovisnu o tipu problema i obliku ulaznih podataka. Slojevi se najčešće slažu u linearom slijedu za sekvencionalne podatke, no moguće su i ostale topologije. Osim odabira akhitekture mreže, potrebno je odabrati i funkciju gubitka (eng. Loss function) koja se minimizira treniranjem mreže, a predstavlja mjeru točnosti između stvarnih vrijednosti i predikcija. Vrijednost funkcije gubitka, tj. pogreška, povratnom vezom se propagira na težine slojeva pomoću optimizacijskog algoritma (npr. Adam), najčešće temeljenog na stohastičkom smanjenju gradijenta (eng. Stochastic gradient descent). Učenje je najčešće završeno kada vrijednost gradijenata svih parametara bude jednaka nuli. Proces treniranja modela prikazan je na slici 3. Odabir prikladne funkcije gubitka ovisi o tipu problema (regresija, klasifikacija), a najčešće se za navedeni tip sekvencionalnih numeričkih podataka koristi srednja kvadratna pogreška (eng. mean-squared error). Treniranje modela dubokog učenja zahtijeva velike računalne resurse, koji određuju 'dubinu' ostvarivog modela kao i brzinu treniranja, a najčešće se izvodi pomoću naprednih grafičkih procesorskih jedinica (eng. Graphics Processing Unit - GPU).



Sl. 2.: Modeliranje sekvencionalnog prognostičkog modela



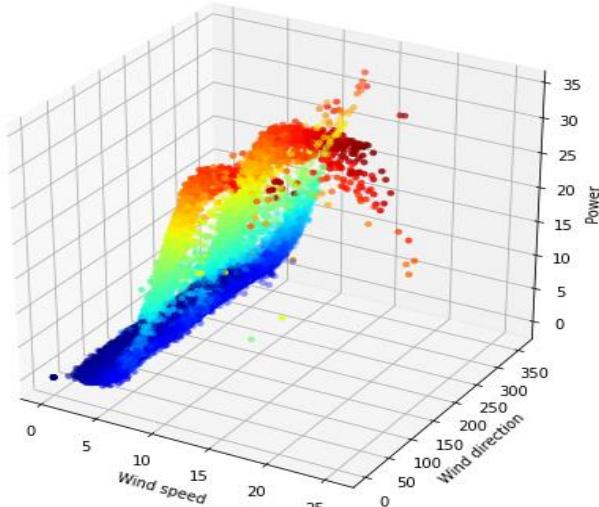
Sl. 3.: Proces treniranja modela dubokog učenja

3. PRIMJENA DUBOKOG UČENJA NA PROGNOZIRANJE PROIZVODNJE VE

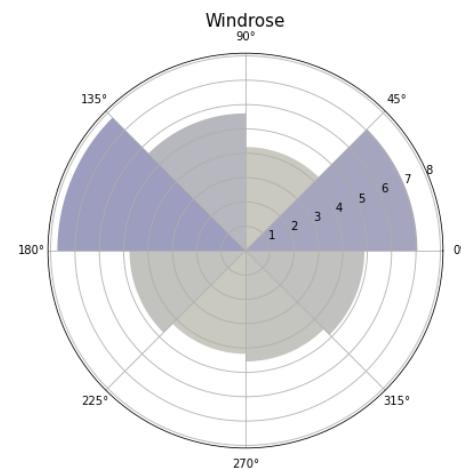
Prije izrade samog modela dubokog učenja, potrebno je pripremiti ulazne podatke, koji najčešće nisu u prikladnom formatu za treniranje modela. Priprema zahtijeva pročišćavanje podataka (uklanjanje nerealnih vrijednosti, popunjavanje praznina itd.), vremensko poravnavanje podataka (npr. svođenje na satne vrijednosti) te formiranje u prikladne podatkovne tenzore. U nastavku će biti prikazan proces treniranja i testiranja modela na stvarnim dvogodišnjim podacima jedne vjetroelektrane u Hrvatskoj.

3.1 Podaci vjetroelektrane

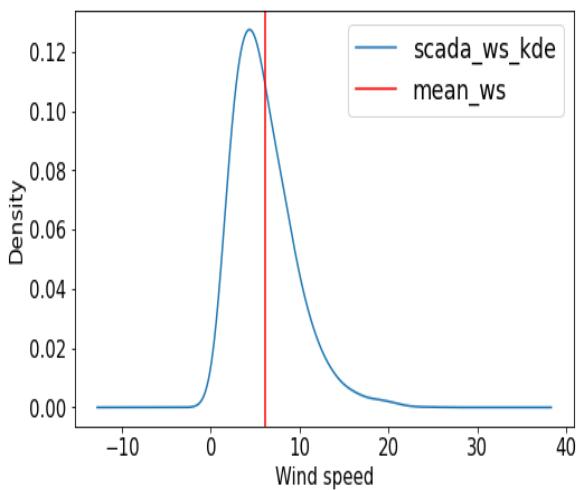
Na slici 4 prikazana su dvogodišnja ostvarenja (od 01.2018. do 01.2020.) proizvodnje iz razmatrane VE, s obzirom na brzinu i smjer vjetra, odnosno prikazana je stvarna krivulja snage elektrane. Na slici 5 prikazana je ruža vjetrova (distribucija vjetra prema učestalosti smjera) sa srednjim brzinama vjetra na radikalnoj osi (npr. u intervalu od sjeverozapadnog do zapadnog vjetra (135° - 180°) prosječna brzina vjetra je 7.72 m/s). Također, prosječna brzina vjetra je proporcionalna učestalosti smjera vjetra, prema čemu su dominantni vjetrovi bura i maestral. Slika 6 prikazuje distribuciju brzine vjetra na lokaciji uz oznaku srednje brzine vjetra od 6 m/s (crvena linija). Konačno, slika 7 prikazuje matricu korelacije mjerenih parametara u sustavu SCADA (brzina i smjer vjetra, radna snaga, temperatura i tlak). Očekivano je da brzina vjetra ima pozitivnu korelaciju sa snagom VE veću od 0.9, dok smjer vjetra, tlak i temperatura pokazuju blago negativnu korelaciju sa snagom elektrane.



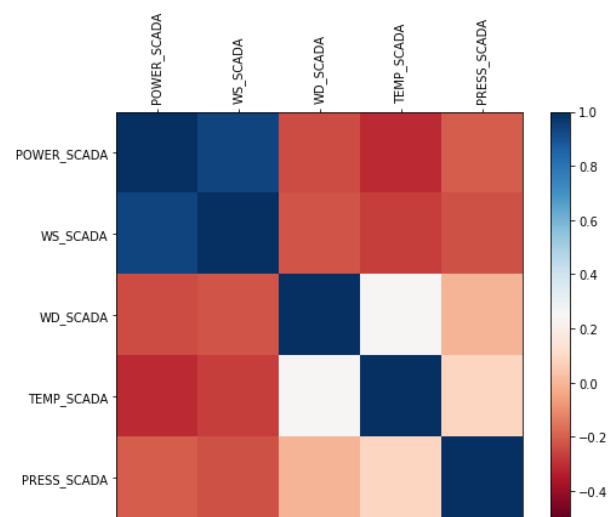
Sl. 4.: Proizvodnja VE u odnosu na brzinu i smjer vjetra



Sl. 5.: Ruža vjetrova sa srednjom brzinom vjetra



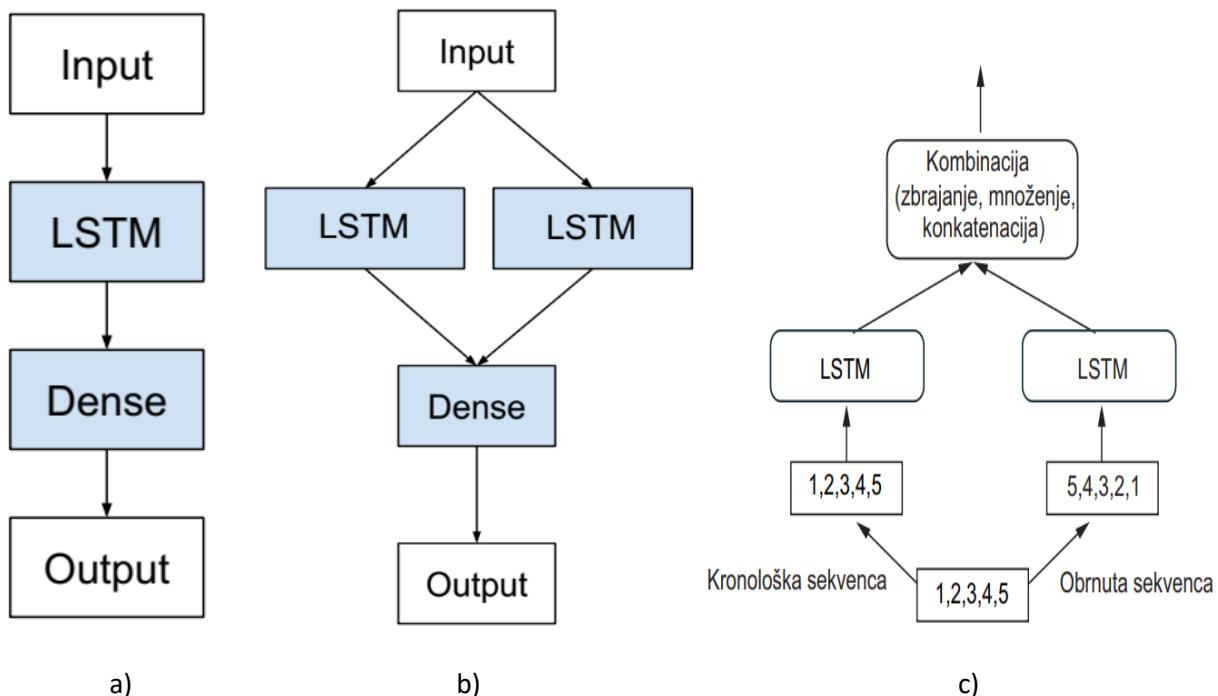
Sl. 6.: Distribucija brzine vjetra na lokaciji VE



Sl. 7.: Matrica korelacije mjerenih parametara

3.2 Model

Kao ulazni prediktori modela korišteni su dvogodišnje prognoze brzine i smjera vjetra iz Aladin 2 meteorološkog modela (NWP). Prognoze brzine i smjera vjetra su u obliku satnih sekvenci s duljinom 72 h, koje se računaju četiri puta dnevno, odnosno svakih šest sati. Ukupan broj dostupnih sekvenci u dvogodišnjem razdoblju se standardno dijeli na tri dijela: trening, validacija i test u odnosu 70%, 10%, 20% (odnos je proizvoljan). Za potrebe izrade modela korišten je programski jezik Python 3 uz specijalizirani modul za duboko učenje Keras uz Tensorflow za operacije s tenzorima. Na slici 8 prikazana je struktura dva korištena modela. Prvi model (slika 8a) je sastavljen od jednog LSTM sloja i jednog gusto povezanog sloja (eng. Dense layer). Navedeni model procesuira sekvence samo u kronološkom slijedu. Drugi korišteni model je prikazan na slici 8b (dvosmjerni LSTM) koji procesuira sekvence u kronološkom i u obrnutom slijedu. Unutarnje stanje LSTM ćelije unaprijedne i obrnute sekvence kombinira se jednom od mogućih funkcija te proslijeđuje sljedećem sloju (slika 8c).



S1. 8.: a) Jednosmjerni LSTM model (model 1); b) Dvosmjerni LSTM model (Bi-LSTM) (model 2); c) Princip rada Bi-LSTM-a

Na slici 9 su prikazani slojevi i pripadni parametri koji se podešavaju tijekom treninga. Očito je da dvosmjerni LSTM model ima skoro dvostruku veću unutarnju memoriju. Količina unutarnje memorije je proizvoljan (hiper)parametar modela, kao i mnogi drugi parametri koje je potrebno zadati prije treniranja.

Model: "sequential_15"

Layer (type)	Output Shape	Param #
<hr/>		
lstm_15 (LSTM)	(None, 72, 50)	10600
dense_26 (Dense)	(None, 72, 50)	2550
dense_27 (Dense)	(None, 72, 1)	51
<hr/>		
Total params:	13,201	
Trainable params:	13,201	
Non-trainable params:	0	

a)

Model: "sequential_10"

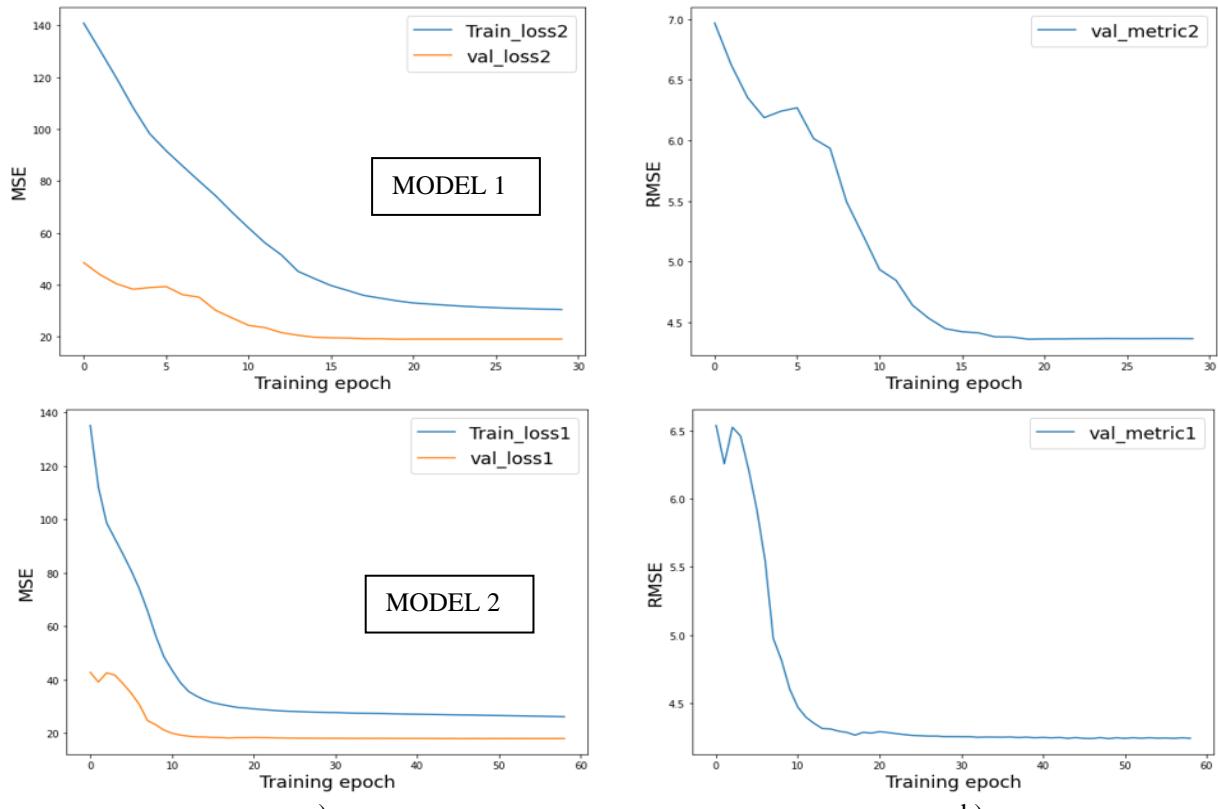
Layer (type)	Output Shape	Param #
<hr/>		
bidirectional_9 (Bidirectional multiple)		21200
dense_16 (Dense)	multiple	2550
dense_17 (Dense)	multiple	51
<hr/>		
Total params:	23,801	
Trainable params:	23,801	
Non-trainable params:	0	

b)

S1. 9.: a) Parametri modela 1; b) Parametri modela 2

3.3 Rezultati

Na slici 10a prikazan je proces treniranja i validacije modela 1 i 2. Model se zaustavlja s treningom kada funkcija gubitka (srednja kvadratna pogreška – MSE) na validacijskim podacima nema promjene određeni broj epoha (npr. 10 epoha). Slika 10b prikazuje korijen srednje kvadratne pogreške (RMSE) između prognoziranih sekvenci i stvarnih vrijednosti na validacijskim podacima (korijen funkcije gubitka na validacijskim podacima), odnosno validacijsku metriku modela. Očigledno je da model 2 brže postiže minimum funkcije gubitka te je ukupni RMSE povoljniji u slučaju dvostrjnog LSTM-a, što je posljedica veće unutarnje memorije modela 2



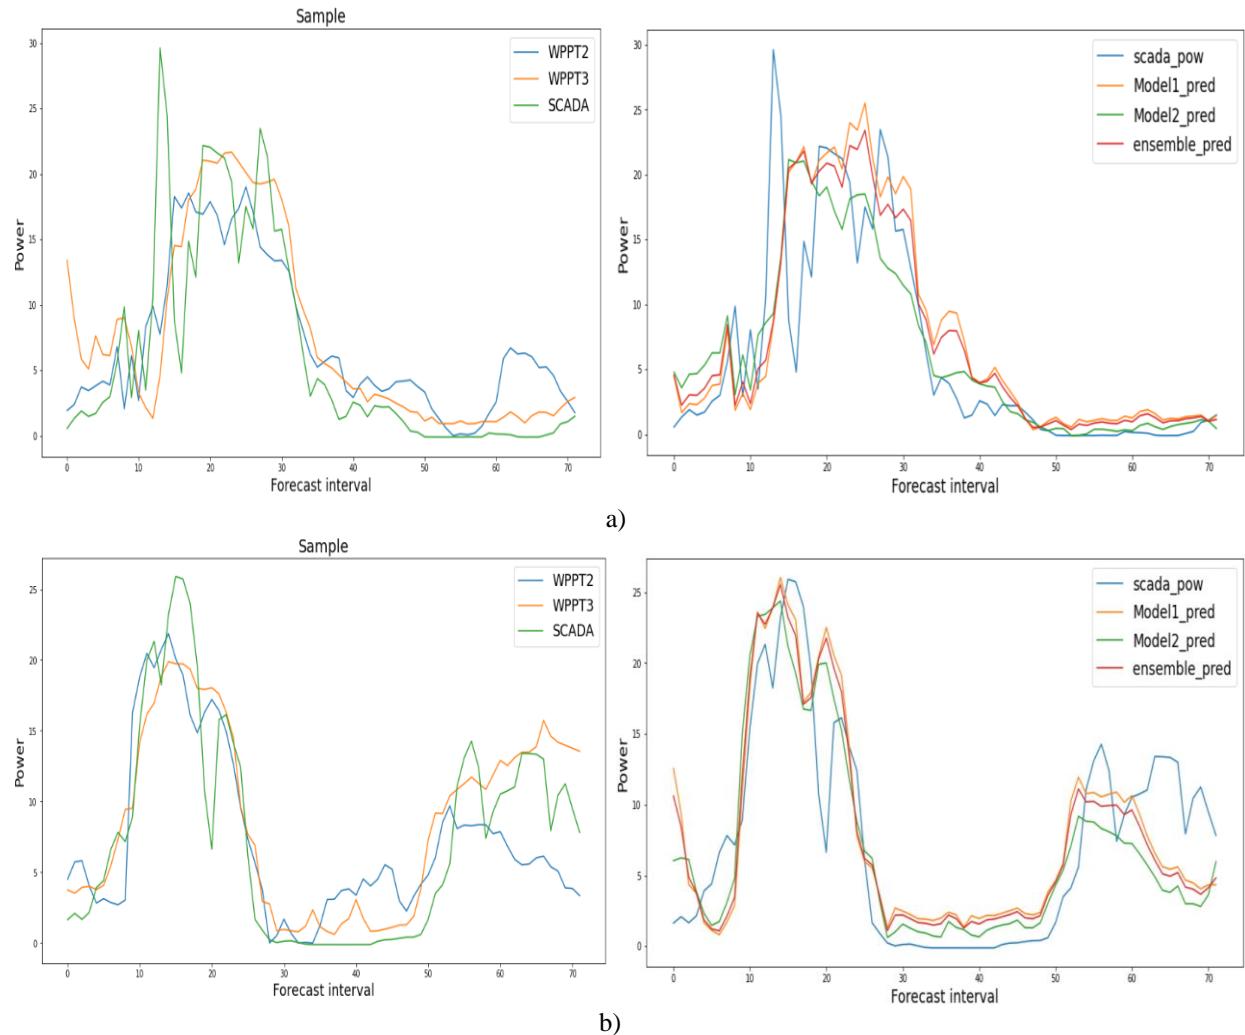
Sl. 10.: a) Funkcija gubitka modela 1 i 2 (trening i validacija); b) metrika točnosti modela na validacijskim podacima (RMSE)

Na slici 11 prikazana je usporedba komercijalnih alata (WPPT2 i WPPT3) na testnim podacima, u odnosu na stvarna mjerena iz SCADA sustava te prognoze i prikazanih modela dubokog učenja. Dodatno, moguće je težinski vrednovati prognoze oba modela te dobiti usrednjenu prognozu koja može pružati bolje rezultate (crvena krivulja - ensemble_pred). Vidljivo je da predloženi modeli pružaju prognoze komercijalne točnosti i s relativno jednostavnom strukturu modela. Dakako, složeniji i 'dublji' modeli mogli bi pružiti bolje rezultate. Zanimljivo je napomenuti da WPPT2 alat koristi jednake NWP prognoze (Aladin2) kao i korišteni ulazni podaci u ovom radu, dok WPPT3 koristi višestruke NWP izvore prognoza (Enfor).

ZAKLJUČAK

U radu je prikazan jedan od načina primjene dubokog učenja u prognoziranju proizvodnje vjetroelektrana pomoću rekurentnih mreža za sekvenčne podatke. Razjašnjen je način pripreme i struktura podataka te struktura modela za prognoziranje sekvenci. Konačno, grafički je prikazana usporedba prognoza iz predloženih modela i komercijalnih alata na dva uzorka, pružajući uvid u točnost prognoza dobijenih pomoću metoda dubokog učenja. Može se zaključiti da se razvijenim jednostavnim modelom mogu postići vrlo dobri rezultati u predviđanju proizvodnje VE usporedivi s onim dobivenim

komercijalnim alatima. Buduća istraživanja će se usmjeriti na razvoj sliženijih modela dubokog učenja kako bi se postigla bolja prognoza proizvodnje VE.



Sl. 11.: Usporedba prognoza iz komercijalnih alata i prikazanih modela a) uzorak 1 b) uzorak 2

ZAHVALA

The work of the authors is a part of the H2020 project CROSSBOW – CROSS BOnder management of variable renewable energies and storage units enabling a transnational Wholesale market (Grant No. 773430). This document has been produced with the financial assistance of the European Union. The contents of this document are the sole responsibility of authors and can under no circumstances be regarded as reflecting the position of the European Union. This work has been supported in part by the Croatian Science Foundation under the project WINDLIPS – WIND energy integration in Low Inertia Power System (grant No. HRZZ-PAR-02-2017-03).

LITERATURA

- [1] J. Jung i R. Broadwater, »Current status and future advances for wind speed and power forecasting,« *Renewable and Sustainable Energy Reviews*, svez. 31, pp. 762-777, March 2014.
- [2] G. Giebel, "The State-Of-The-Art in Short-Term Prediction of Wind Power - A Literature Overview," Project ANEMOS, 2003.
- [3] Y. Ding, Data Science For Wind Energy, Chapman And Hall/CRC, 2020.
- [4] J. Đaković and I. Kuzle, " Status i klasifikacija metoda za prognoziranje proizvodnje električne energije iz vjetroelektrana " 13. Simpozij o vođenju sustava HRO Cigre, Rovinj, Hrvatska, 2018.

- [5] I. Kuzle, M. Klarić and H. Pandžić, "Feasibility Assessment of a Wind Power Plant with Insufficient Local Wind Data Using Cascade-Correlating Neural Network," *Strojarstvo*, vol. 53, no. 6, pp. 455-462, 2011.
- [6] V. Bali and A. Kumar, "Deep Learning based Wind Speed Forecasting-A Review," in *9th International Conference on Cloud Computing, Data Science & Engineering*, Noida, India, 2019.
- [7] L. Han, R. Zhang, X. Wang, A. Bao and H. Jing, "Multi-step wind power forecast based on VMD-LSTM," *IET Renewable Power Generation*, vol. 13, no. 10, pp. 1690 - 1700, 2019.
- [8] J.-F. Toubeau, J. Bottieau, F. Vallée and Z. D. Grève, "Improved Day-Ahead Predictions of Load and Renewable Generation by Optimally Exploiting Multi-Scale Dependencies," in *ISGT-Asia*, 2017.
- [9] F. Chollet, Deep learning with Python, Manning, 2017.
- [10] K. Jurković, H. Pandžić , I. Kuzle, "Review on unit commitment under uncertainty approaches," in *38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO 2015)*, Opatija, Croatia, May 2015.
- [11] J. Brownlee, Long Short-Term Memory Networks With Python, 2018.