

# Napredne metode prognoziranja proizvodnje iz vjetroelektrana

## Kvalifikacijski doktorski ispit

Josip Đaković

Sveučilište u Zagrebu Fakultet elektrotehnike i računarstva  
Zavod za visoki napon i energetiku  
Zagreb, Hrvatska  
e-mail : josip.djakovic@fer.hr

**Sažetak** — Trend povećane integracije vjetroelektrana u elektroenergetski sustav predstavlja izazov za operatore prijenosnog i distribucijskog sustava te operatora tržišta 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. Stoga, vođenje elektroenergetskog sustava s visokim udjelom obnovljivih izvora zahtijeva nove metode uravnoteženja proizvodnje i potrošnje električne energije. Učinkovito kratkoročno prognoziranje iz vjetroelektrana predstavljat će ključni faktor za pouzdanu integraciju velikog udjela proizvodnje iz vjetroelektrana. U radu su predstavljeni aktualni načini prognoziranja proizvodnje i njihova klasifikacija po vremenskom horizontu, modelu predviđanja, točnosti te dometu (razini) predviđanja. Razmotrene su prednosti i nedostaci reprezentativnih metoda, odnosno mogućnost primjene pojedinih metoda u ovisnosti o dostupnim ulaznim podacima i vremenskom horizontu. Dodatno, navedeni su izazovi i poteškoće povezane s predviđanjem proizvodnje, kao i metode za povećanje točnosti prognoze. Konačno, predstavljene su glavne smjernice i zahtjevi za budući razvoj naprednih metoda prognoziranja te je dan prijedlog metoda koje odgovaraju specifičnoj situaciji u hrvatskom elektroenergetskom sustavu.

**Ključne riječi**— predviđanje proizvodnje, vjetroelektrane, klasifikacija metoda prognoziranja, statističke metode, fizikalne metode, hibridne metode

### POPIS KRATICA

ALADIN	Aire Limitée Adaptation Dynamique développement InterNational	k-NN	k-Nearest Neighbors
ANN	Artificial Neural Network	LIDAR	Light Detection and Ranging
AR	Auto-Regressive	MA	Moving Average
G(ARCH)	(Generalized) Autoregressive Conditional Heteroskedasticity	MAE	Mean Absolute Error
ARIMA	Auto-Regressive Integrated Moving Average	MAID	Mean Absolute Interval Deviation
ARMA	Auto-Regressive Moving Average	MAPE	Mean Absolute Percent Error
ARMAX	Auto-Regressive Moving Average eXogenous	MAS	Multiple Architecture System
ARX	Auto-Regressive eXogenous	MASE	Mean Absolute Scaled Error
CDF	Cumulative Density Function	MCP	Measure-Correlate-Predict
EES	Elektroenergetski sustav	MLP	Multi-layer Perceptron
GA-ANN	Genetic Algorithm-ANN	MLR	Multiple Linear Regression
GRNN	Generalized regression neural network	MOS	Model Output Statistics
KDE	Kernel Density Estimation	NARMAX	Non-linear ARMA eXogenous
		NWP	Numerical Weather Predictions
		OIE	Obnovljivi izvori energije
		PDF	Probability Density Function
		QR	Quantile Regression
		RBF	Radial Basis Functions
		RF	Random Forests
		RMSE	Root Mean Square Error
		SARIMA	Seasonal Auto-Regressive Integrated Moving Average
		SDE	Standard Deviation of Errors
		SVM	Support Vector Machine
		SVR	Support Vector Regression
		VARX	Vector Auto-Regression eXogenous
		VE	Vjetroelektrane
		WPMS	Wind Power Management System
		WPPT	Wind Power Prediction Tool
		VS	Vremenske serije

## I. UVOD

Proizvodnja energije iz obnovljivih izvora (OIE), od kojih najveći udio čini proizvodnja iz vjetroelektrana (VE), imaće sve značajniji utjecaj u ostvarivanju niskougljičnog razvoja energetskog sektora zbog kontinuirane penetracije u elektroenergetski sustav (EES). Iako integracija vjetroelektrana donosi mnoge pogodnosti s ekološkog aspekta, nepredvidiva i promjenjiva narav proizvodnje iz VE predstavlja mnoge izazove za operatore EES-a (ekonomsko dispečiranje elektrana, dinamička stabilnost sustava), operatore tržišta električne energije, te za proizvođače i trgovce električnom energijom iz VE. Jedno od mogućih rješenja za navedene izazove je razvoj naprednih alata i metoda za pouzdano kratkoročno prognoziranje proizvodnje iz VE [1]. Osim navedenog, dugoročne prognoze proizvodnje se mogu koristiti u planiranju održavanja proizvodnih jedinica i drugih komponenti EES-a, no točnost im se značajno smanjuje za vremenske intervale veće od 5-7 dana unaprijed [2]. Najznačajnija primjena kratkoročnog prognoziranja proizvodnje iz VE očituje se u smanjenju potreba za energijom uravnoteženja, odnosno rezervom snage, koja je neophodna za pokrivanje odstupanja VE od ugovornog rasporeda [3]. Posljedica toga su niži troškovi i veća penetracija VE, manji zahtjevi za regulacijskim rezervama te niže cijene električne energije za sve potrošače u EES-u [4], [5], [6].

Zbog navedenih razloga mnogo truda se ulaže u razvoj preciznih metoda prognoziranja, prilagođenih različitim potrebama korisnika, tj. zahtjevima za razinom točnosti [7]. U novije vrijeme, veća pozornost se usmjerava i na prognoziranje relativne promjene proizvodnje zbog jakih i kratkotrajnih vremenskih nepogoda (eng. ramp forecasting) što značajno može utjecati na stabilnost EES-a [8], [9]. Zbog različitih zahtjeva za prognozom i činjenice da se modeli prilagođavaju lokalnim karakteristikama proizvodnog područja, teško je izdvojiti pojedine modele kao generalno bolje od drugih.

U poglavlju II, napravljen je pregled i klasifikacija metoda prognoziranja proizvodnje po vremenskom horizontu, modelu predviđanja, točnosti i dometu (području). Prezentirane su prednosti i nedostaci pojedinih modela, njihova primjenjivost na specifične slučajeve te trendovi i smjernice budućeg razvoja naprednih metoda prognoziranja proizvodnje. U poglavlju III su opisane trenutačne metode prognoziranja u Hrvatskoj.

## II. METODE PROGNOZIRANJA PROIZVODNJE IZ VE

Osnovna svrha prognostičkih metoda je pružiti uvid u očekivane brzine vjetra i proizvodnje iz VE u periodu od nekoliko minuta, nekoliko sati ili dana, ovisno o potrebama vođenja sustava. Metode prognoziranja proizvodnje generalno možemo podijeliti u dva pristupa. Prvi pristup (statistički) karakterizira prognoziranje pomoću statističkih modela, treniranih pomoću velikom broja povijesnih meteoroloških podataka i podataka o proizvodnji VE (vremenskih serija), koji kao ulazne podatke koriste meteorološke prognoze iz NWP (eng. Numerical Weather Prediction) modela te dostupna mjerenja u stvarnom vremenu. Drugi pristup (fizikalni) čine metode koje kao ulazne podatke koriste meteorološke prognoze te detaljne fizikalne karakteristike terena na lokacijama vjetroelektrana te karakteristike vjetroparka (raspored turbina, proizvodne karakteristike vjetroagregata i sl.) [1]. Korištenje fizikalnih karakteristika terena i vjetroparka, čini osnovnu razliku

između dva navedena pristupa. Razne kombinacije navedenih pristupa, koje iskorištavaju prednosti pojedinih metoda, se često u literaturi svrstavaju pod hibridni (kombinirani) pristup [10].

### A. Vremenske serije

#### Analiza vremenskih serija

Vremenske serije (VS) (eng. time series) su setovi numeričkih podataka indeksiranih u vremenskom slijedu. Razlikujemo diskretne i kontinuirane vremenske serije. Diskretne VS su one u kojima se opažanje vrši u diskretnim vremenskim intervalima, dok u kontinuiranim vršimo kontinuirana opažanja u određenom vremenskom intervalu. Analizu VS je moguće vršiti u frekvencijskoj (spektralna i valična analiza) i vremenskoj domeni (autokorelacija i međusobne korelacije). Nadalje, analizu VS se može podijeliti u parametarsku i neparametarsku. Parametarske metoda pretpostavlja određenu strukturu stohastičkog procesa, koja se može opisati određenim brojem parametara, dok neparametarske ne pretpostavljaju strogu strukturu procesa. Konačno, moguća podjela analize VS je na linearne i nelinearne, te prema broju analiziranih serija na univarijantne i multivarijantne [11].

Općenitu vremensku seriju  $y_t$  možemo prikazati kao aditivnu (1) ili multiplikativnu (2) kombinaciju sezonske komponente  $S_t$ , komponente trend-ciklus  $T_t$  te komponente ostatka (slučajne komponente)  $R_t$  [12]:

$$y_t = S_t + T_t + R_t \quad (1)$$

$$y_t = S_t * T_t * R_t \quad (2)$$

Identifikacija komponenta serije se provodi nekom od metoda dekompozicije (klasična, X11, SEATS, STL). Vremenske serije koje sadrže komponente trenda ili sezone su nestacionarne, dok serije čija svojstva ne ovise o trenutku opažanja nazivamo stacionarnim (sadrže samo bijeli šum). Karakteristika stacionarnih VS je da imaju statistička svojstva, kao što su očekivana vrijednost, varijanca i kovarijanca, vremenski neovisna. Kako je većina VS modela bazirana na pretpostavci o stacionarnosti, a gotovo sve realne vremenske serije uglavnom sadrže neki oblik nestacionarnosti, potrebno je transformirati serije u stacionarne (npr. Box-Cox transformacijama), odnosno ukloniti nestacionarnosti. Prognostičke metode se nakon toga primjenjuju na stacionarne serije, te u posljednjem koraku pridodaju im se komponente trenda i sezone. Osim dekompozicije VS, moguće je primijeniti diferenciranje serije, odnosno odrediti seriju razlika između uzastopnih opažanja.

#### Prognoziranje vremenskih serija

Prognoziranje vrijednosti VS se vrši pomoću modela baziranog na povijesnim (promatranima, mjerenim) vrijednostima. Najjednostavnija metoda prognoziranja u vremenskoj domeni je ustrajnost (eng. naive method, persistence) kojom se pretpostavlja da će buduća vrijednost biti jednaka zadnjoj mjerenoj vrijednosti. Neke od najpoznatijih skupina modela za prognoziranja u vremenskoj domeni su:

- eksponencijalno izravnavanje (eng. exponential smoothing) – prognozirana vrijednost se računa pomoću težinske sume posljednjih nekoliko mjerenih vrijednosti na način da se najveća težina pridodaje posljednjoj mjerenoj

vrijednosti, a težine ostalih vrijednosti eksponencijalno opadaju prema najstarijim mjerenim vrijednostima. Različite varijante eksponencijalnog izravnavanja omogućuju prognoziranje serija koje se ponašaju prema određenim obrascima trenda ili imaju sezonske varijacije

- Skupina ARIMA modela – generalna skupina linearnih modela koji se baziraju na stacionarnosti VS. Za potrebe prognoziranja proizvodnje mogu se izdvojiti neki od standardnih regresijskih modela: autoregresivni model (eng. Auto-Regressive model-AR), model pomičnog prosjeka (eng. Moving Average model-MA), autoregresivni model pomičnog prosjeka (eng. Auto-Regressive Moving Average model-ARMA) te autoregresivni integrirani model pomičnog prosjeka (eng. Auto-Regressive Integrated Moving Average model-ARIMA). Generalna forma navedenih modela je:

$$X_t = C + \varepsilon_t + \sum_{i=1}^p \varphi_i \cdot X_{t-i} + \sum_{i=1}^q \vartheta_i \cdot \varepsilon_{t-i} \quad (3)$$

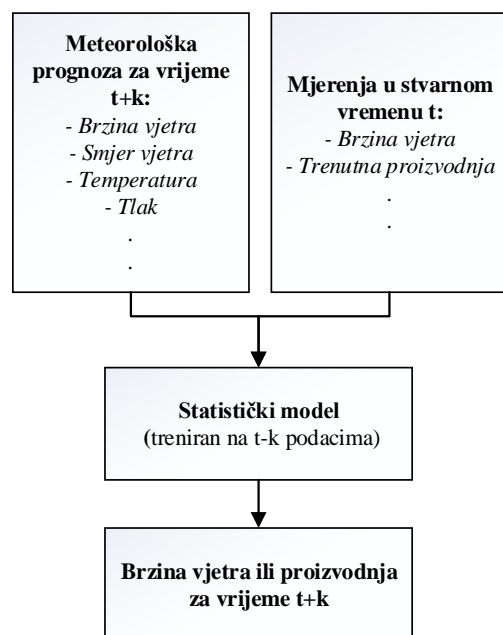
gdje  $X_t$  predstavlja prognoziranu varijablu u trenutku  $t$ ,  $\varphi_i$  je autoregresijski parametar,  $\vartheta_i$  je parametar pokretnog srednjaka,  $C$  je konstanta te  $\varepsilon_t$  predstavlja bijeli šum. Navedeni model predstavlja ARMA model s autoregresivnim modelom reda  $p$  te model pomičnog prosjeka reda  $q$  što se označava s ARMA( $p,q$ ). Ako je red MA modela nula, tada se model reducira na autoregresivni model reda  $p$ , AR( $p$ ), dok u slučaju da je red autoregresivnog modela jednak nuli, tada se model svodi na MA model reda  $q$  (MA( $q$ )). Na serijama koje imaju komponentu trenda vrši se diferencijacija (po potrebi višestruka) kako bi se dobila stacionarna serija. Iz navedenog proizlazi *Integrated* u nazivu ARIMA skupine, koji navodi mogućnost modeliranja diferencirane serije. Modeli koji opisuju serije sa sezonskom komponentom pripadaju skupini (S)ARIMA modela. (Sezonski)-ARIMA predstavlja poopćenje ARIMA modela. Proširenje navedenih modela je modeliranje odnosa vektorskih VS, što spada u skupinu multivarijantnih modela (npr. VAR). Osim toga, moguće je analizirati utjecaj vanjskih (egzogenih) (eng. forcing, exogenous) varijabli na promatrane seriju. Razlika između vektorskog pristupa je što egzogene varijable mogu biti determinističke, odnosno kontrolirane)

- Nelinearni modeli - u ovu skupinu spadaju modeli koji mogu modelirati nelinearne autoregresijske odnose vremenski serija (npr. NARX, ARCH, GARCH), modeli strojnog učenja (umjetna inteligencija, stroj potpornih vektora, k-NN, Markovljevi procesi itd.)

Statističko prognoziranje proizvodnje iz VE uključuje pronalaženje optimalnih modela koji opisuju kompleksne međusobne kvantitativne (regresija) i kvalitativne (klasifikacija) odnose višestrukih vremenskih serija. Prema tome, složenost prognoziranja vremenskih serija, kao što je brzina vjetra i proizvodnja iz VE, može varirati od relativno jednostavnih autoregresijskih modela pa do vrlo složenih regresijskih i klasifikacijskih metoda koje primjenjuju elemente strojnog učenja i umjetne inteligencije. Izbor i uspješnost metode prognoziranja, osim sposobnosti pronalaska optimalnog modela, uvelike ovisi i o dostupnosti te kvaliteti ulaznih podataka.

## B. Statistički pristup

Statistički pristup omogućuje prognoziranje proizvodnje iz VE na temelju modela koji uspostavljaju odnos između povijesnih meteoroloških i proizvodnih podataka, prognoziranih meteoroloških vrijednosti u trenutku  $t + k$ , te podataka mjerenih u stvarnom vremenu  $t$  (npr. trenutna proizvodnja i brzina vjetra). Parametri statističkih modela se inicijalno procjenjuju na temelju povijesnih podataka, ali kako s vremenom postaju dostupni novi pogonski i meteorološki podaci, parametri se ažuriraju u svrhu povećanja točnosti prognoze (Slika 1). Statistički pristup zahtijeva veliku količinu povijesnih podataka, što ga čini neprikladnim za nove lokacije VE koje nemaju dovoljno veliku bazu pogonskih podataka za treniranje statističkog modela. Statistički modeli se mogu podijeliti na regresijske i klasifikacijske, ali i na konvencionalne i modele koji koriste koncepte umjetne inteligencije [13], [14], [15].



Slika 1: Statistički pristup prognoziranja (prema [1])

Regresijski modeli treniraju se vremenskim serijama dostupnih podataka (proizvodnja, brzina i smjer vjetra, tlak) te primjenjuju za prognozu brzine vjetra ili proizvodnje. Razlika između regresijskih i klasifikacijskih modela je u izlaznim varijablama, odnosno izlazna varijabla regresije je kontinuirana numerička vrijednost, dok je klasifikacije diskretna (nebrojana) vrijednost, tj. klasa. Proces stvaranja matematičkog modela za prognoziranje vremenskih serija, prema Box-Jenkins metodologiji<sup>1</sup>, može se podijeliti na tri glavna koraka koji uključuju identifikaciju modela, estimaciju te dijagnostičku provjeru [16]. Neki od radova baziranih na prognozama pomoću ARIMA modela su [17], [18], [19]. U [20] je pokazano da ARIMA-ARCH model ostvaruje točniju prognozu vjetra od ARIMA modela. GARCH model je primijenjen u [21] za prognoziranje proizvodnje iz VE. Osim navedenih modela u literaturi se mogu pronaći metode kao što su: AR-eXogenous (ARX)

<sup>1</sup> Box-Jenkins metodologija koristi ARIMA modele za analizu vremenskih serija.


[22] modeli koji koriste egzogene varijable u AR modelu te slični radovi koji kombiniraju egzogene varijable s navedenim regresijskim modelima, npr. [23]. Poznati prognostički alat *Wind Power Prediction Tool 2–WPPT2* je baziran na ARX modelu, gdje brzina vjetra predstavlja egzogenu varijablu. Model je formuliran u sljedećem obliku [24]:

$$p_{t+k} = a_1 p_t + a_2 p_{t-1} + b_1^m w_{t+k|t}^m b_2^m (w_{t+k|t}^m)^2 + \sum_{j=1}^2 \left[ c_j^c \cos\left(\frac{2j\pi h_{t+k}^{24}}{24}\right) + c_j^s \sin\left(\frac{2j\pi h_{t+k}^{24}}{24}\right) \right] + m + e_{t+k} \quad (4)$$

gdje  $p_t$  predstavlja mjerenu snagu u vremenu  $t$ ,  $w_{t+k|t}^m$  je prognozirana brzina vjetra u trenutku  $t+k$ ,  $h_{t+k}^{24}$  je vrijeme u danu u trenutku  $t+k$ ,  $e_{t+k}$  je bijeli šum, a  $a_1, a_2, b_1^m, b_2^m, c_j^c, c_j^s$  i  $m$  predstavljaju promijenjive parametre modela. AR model koji koristi Bayesovu statistiku prikazan je u [25]. U radu je primijenjena Box-Cox transformacija za normaliziranje serije. Parametri AR modela su procijenjeni metodama markovljevih lancima i Monte Carlo simulacija. Konvencionalni modeli bazirani na Box-Jenkins metodologiji se uglavnom koriste kao referentni modeli za vrlo kratko i kratkoročno prognožiranje zbog njihove jednostavne formulacije.

U napredni oblik statističkih modela koji koriste metode umjetne inteligencije mogu se svrstati neuronske mreže, klasifikator najbližih susjeda (k-NN metoda), (eng. k-Nearest Neighbors), metodu potpornih vektora (eng. Support Vector Machine-SVM), metoda slučajne šume (eng. Random Forests-RF), valična analiza (eng. Wavelet analysis) i drugi, što su sve algoritmi za rudarenje podataka.

Neuronske mreže, koje su najpoznatiji oblik umjetne inteligencije, treniraju se pomoću velikih skupova povijesnih i NWP podataka kako bi odredili međuovisnost ulaznih i izlaznih varijabli. Standardna neuronska mreža sastoji se od ulaznog sloja, jednog ili više skrivenih slojeva i izlaznog sloja. Svaki sloj se sastoji od nekolicine umjetnih neurona povezanih sa svim ostalim neuronima u susjednim slojevima. Neuronske mreže omogućuju modeliranje složenih nelinearnih relacija između ulaznih i izlaznih varijabli kroz podešavanje težinskih faktora neurona koristeći različite metode učenja [26], [27]. Navedeni pristup ne zahtijeva formiranje eksplicitnih matematičkih izraza kao u klasičnim regresijskim modelima. Dodatno, neuronske mreže imaju mogućnost samostalnog učenja, organizacije i prilagodbe. Na slici 3 prikazana je jedna od mogućih konfiguracija neuronske mreže za prognožiranje proizvodnje iz vjetroelektrana. Neuronske mreže se koriste u mnogim kombinacijama i strukturama za prognožiranje proizvodnje. Neuronske mreže se mogu podijeliti u dvije kategorije: unaprijedne (eng. feed-forward neural networks-FFNN) i rekurzivne (eng. recurrent neural networks-RNN) neuronske mreže [28]. U unaprijednim mrežama proces proračuna parametara mreže teče samo u jednom smjeru, dok rekurzivne mreže imaju neki oblik povratnih veza u strukturi. Neki od radova koji koriste FFNN za prognožiranje proizvodnje su [29] i [30]. Jedna od najjednostavnijih ANN metoda je višestruki perceptron (eng. Multy-Layer Perceptron). U [31] autori su usporedili SVM i MLP metode te demonstrirali značajno veće prognostičke performance SVM metode. Osim navedenog, u literaturi se mogu naći metode genetičkih neuronskih mreža [32], metode koje koriste optimizaciju rojem čestica u svrhu poboljšanja procesa treniranja neuronskih mreža za kratkoročno prognožiranje proizvodnje [33] i sl.



Slika 2: Primjer neuronske mreže za prognožiranje proizvodnje iz VE [34]

Algoritam klasifikator najbližih susjeda (k-NN) je neparameterska metoda koja se koristi za klasifikaciju i regresiju. U oba slučaja, ulaz se sastoji od  $k$  najbližih vrijednosti za treniranje, dok izlaz ovisi o tome koristi li se metoda za klasifikaciju ili regresiju. U slučaju k-NN regresije, izlazna vrijednost je srednja vrijednost  $k$  najbližih susjednih vrijednosti [35].

Metoda potpornih vektora ima veliku mogućnost generalizacije i analiziranje nelinearnih problema. U slučaju

ove metode radi se o skupu povezanih metoda učenja koje se koriste za klasifikaciju i regresiju, mapiraju se ulazni vektori u višedimenzionalni prostor te se tako stvara višedimenzionalna ploha koja dijeli klase ulaznih vektora. Rade na principu višestruke linearne regresije koristeći transformirane prediktore uz zadržavanje niske složenosti i dobrog poklapanja podataka [36], [37], [38].

Model slučajne šume je klasifikator koji se sastoji od skupine regresijskih stabala (stabala odluke) čiji rezultati prikazuju srednju prognozu pojedinih stabala. Korištenjem usrednjenih

rezultata više regresijskih stabala moguće je smanjiti varijancu na račun povećanja srednje pogreške (eng. bias). Unatoč tome, točnost modela se povećava [39], [40].

Valična analiza se temelji na teorijama harmoničke, funkcionalne i Fourierove analize. Valići su funkcije koje mogu imati bilo kakav oblik, ali su vremenski ograničene. Multirezolucijsko predstavljanje signala je osnovno načelo valične transformacije, koja za razliku od Fourierove transformacije, signal prikazuje istodobno u vremenskoj i frekvencijskoj domeni [41], [42], [43].

### C. Fizikalni pristup

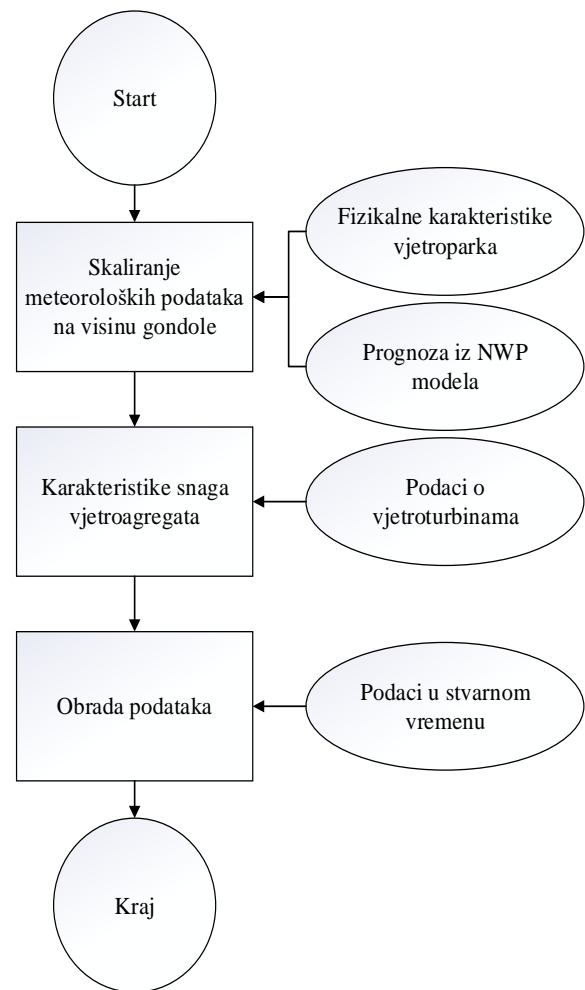
Fizikalni pristupi temelje se na detaljnom modeliranju meteoroloških pojava u atmosferskom graničnom sloju<sup>2</sup> pomoću fizikalnih karakteristika terena u okolici VE (orografija, hrapavost, prepreke itd.), na temelju kojih se podaci iz NWP (eng. Numerical Weather Prediction) modela skaliraju na visinu gondole turbine (eng. downscaling) [44]. Nakon toga, prognozirane brzine vjetra se prebacuju u prognoziranu proizvodnju iz VE pomoću karakteristika proizvodnje, dostavljenih od strane proizvođača ili formiranih na temelju stvarnih mjerenja na lokaciji VE [45]. Osim karakteristika proizvodnje, potrebno je uračunati efekte zavjetrine, koji mogu značajno utjecati na efikasnost agregata. U slučaju dostupnosti mjerenja u stvarnom vremenu, moguće je primijeniti statističko post-procesiranje prognoza kako bi se otkonile sistematske pogreške, odnosno povećala točnost prognoza (eng. Model Output Statistic-MOS). Također, ako nije moguće (ili nije potrebno) prognozirati proizvodnju svake VE posebno, moguće je prognozu jedne referentne elektrane skalirati na šire područje za dobijanje regionalne prognoze proizvodnje (eng. regional upscaling). Na slici 2 je prikazan standardni algoritam prognoziranja proizvodnje pomoću fizikalnog pristupa.

Postoje mnogi NWP modeli za modeliranje atmosferskih pojava, baziranih na metodama računalne dinamike fluida (eng. Computational Fluid Dynamics-CFD), a razlikuju se u rezoluciji numeričke mreže, numeričkim računalnim metodama te simuliranim fizikalnim pojavama, koje ovise o rezoluciji modela. Prema rezoluciji numeričke mreže, NWP modeli se dijele na:

- Globalne (1000 km – 10 km)
  - GFS, GME, GEM
- Mezoskalni modeli (10 km – 1 km)
  - HiRLAM, MM5, ALADIN, WRF
- Mikroskalni modeli (100 m – 0.01 m)
  - AIOLOS, WIEN, NOABL

Globalni NWP modeli pružaju granične uvjete za regionalne (mezoskalne) modele, koji se razvijaju za specifične lokacije na kojima je prisutna proizvodnja iz VE. Mezoskalni modeli detaljnije modeliraju lokalne termalne efekte od globalnih. Nadalje, razvijeni su i modeli koji nastoje modelirati atmosferske efekte u blizini VE (mikroskalni), no složenost i modelirana fenomenologija mogu značajno varirati. Ipak, u većini slučajeva potrebna je parametrizacija donjeg

atmosferskog sloja, kako bi se uračunale lokalne karakteristike terena na dinamiku atmosfere.



Slika 3: Algoritam fizikalnog pristupa (prema [1])

Postupak određivanja brzine vjetra na visini gondole se može podijeliti na dva načina [45]:

- Dinamički - stanje atmosfere se svaki puta nanovo proračunava pomoću NWP modela
- Statički - stanje atmosfere se procjenjuje na temelju preglednih tablica (eng. look-up tables), koje sadrže korekcijske faktore brzine vjetra za specifična atmosferska stanja. Postupak kreiranja look-up tablica se može bazirati na metodologiji klasificiranja (eng. classification) ili klasteriranja (eng. clustering) mjerenih podataka.

Kako bi se povećala točnost nesavršenih NWP modela, često se konačna prognoza dobija kao najvjerojatnija vrijednost višestrukih proračuna istog modela, sa variranim inicijalnim parametrima (eng. ensemble forecasting) [46] ili više dostupnih NWP modela (eng. multi-model approach). Osim točkaste prognoze, podaci mogu biti prikazani s intervalima pouzdanosti koji uračunavaju prognozičku nesigurnost.

<sup>2</sup> Atmosferski granični sloj je najniži dio troposfere (debljine do 3 km), koji je u direktnom dodiru sa Zemljinom površinom, a karakterizira ga izrazita turbulencija [46].

Slaganje rezultata iz više modela upućuje na veću pouzdanost prognoze.

Razvoj fizikalnih metoda zahtijeva dobro razumijevanje meteorologije i fizike graničnog atmosferskog sloja. Za razliku od statističkog pristupa koji su "crna kutija" za meteorološke pojave, fizikalnim pristupom je moguće je optimizirati atmosferske modele, te analizirati njihov utjecaj na točnost prognoza. Dodatna razlika fizikalnog modela prema statističkim je da ne zahtijeva povijesne podatke za treniranje modela. No, fizikalni modeli su izrazito osjetljivi na sistematske pogreške, uzrokovane netočnim inicijalnih podacima. Stoga, prikupljanje točnih fizikalnih podataka je glavni nedostatak navedenog pristupa.

Jedan od prvih fizikalnih sustava za prognoziranje je razvijen u Danskoj, a poznat je pod nazivom *Prediktor* [47]. Prediktor koristi podatke iz NWP modela HiRLAM te pomoću lokalnih karakteristika tla, prepreka, termičke stratifikacije (slojevitosti) atmosfere, prilagođava ih na područje VE.

#### D. Kombinirane (hibridne) metode

Hibridni modeli temelje se na ideji kombiniranja različitih pristupa prognoziranja te iskorištavanju pogodnosti svake od pojedinih metoda. Konačni cilj je poboljšanje točnosti, ali kombinirani pristup ne pruža uvijek bolje rezultate u odnosu na pojedinačne metode. U literaturi se mogu pronaći razne kombinacije prognostičkih modela, koje uključuju konvencionalne statističke metode, umjetnu inteligenciju te fizikalne metode [48], od kojih se mogu izdvojiti pristupi temeljeni na neuronskim mrežama i neizrazitoj logici (eng. fuzzy logic). Dok neuronske mreže karakteriziraju dobre značajke u računalnim strukturama nižeg reda, neizrazita logika često se koristi kao mehanizam zaključivanja u složenim računalnim strukturama. U [49] je prikazan sustav s višestrukom arhitekturom (eng. Multiple Architecture System-MAS) za prognoziranje proizvodnje vjetroelektrana koji objedinjuje više regresijskih algoritama u kombinirani pristup predviđanja: višestruka linearna regresija (eng. Multiple Linear Regression-MLR), višeslojni perceptron neuronska mreža (eng. Multi-layer Perceptron-MLP), radijalne neuronske mreže (eng. Radial Basis Functions-RBF) te metodu potpornih vektora. Analizirane su tri kombinacijske strategije: srednja vrijednost, ponderirana srednja vrijednost te nelinearna fuzija. Predložena metoda poboljšava točnost predviđanja u odnosu na točnost pojedinih modela. Dodatno, u literaturi se mogu pronaći kombinacije kao što su: ARIMA-ANN [50], ARIMA-SVM [51], NWP-ANN [52] itd. Većina komercijalnih alata za prognoziranje proizvodnje objedinjuje pojedine fizikalne i statističke procedure (npr. Zephyr – sinergija WPPT-a i Prediktora [53], *Previento*, *SOWIE* itd.).

U tablici 1 su prikazane glavne prednosti i mane statističkog i fizikalnog pristupa prognoziranja proizvodnje.

Tablica 1. Prednosti i nedostaci metoda za prognoziranje proizvodnje

Statistički pristup	Fizikalni pristup
<ul style="list-style-type: none"> <li>+ Dovoljni su povijesni podaci za treniranje modela,</li> <li>+ nije potrebno poznavanje meteoroloških pojava</li> <li>+ANN pristup ne zahtijeva matematičku formulaciju</li> <li>+ brzi proračun</li> </ul>	<ul style="list-style-type: none"> <li>+ Moguće razumjeti fizikalne pojave u graničnom atmosferskom sloju</li> <li>+ Povijesna mjerenja su manje bitna</li> </ul>
<ul style="list-style-type: none"> <li>- Ovisi o kvaliteti i količini dostupnih podataka,</li> <li>- Slučajevi s ograničenim mjerenjima su problematični</li> </ul>	<ul style="list-style-type: none"> <li>- Potrebne detaljne informacije o terenu i elektranama</li> <li>- Potreban izniman trud i ekspertiza za razradu modela</li> </ul>

#### E. Klasifikacija metoda prognoziranja

##### Vremenski horizont

Metode prognoziranja proizvodnje standardno se dijele na četiri skupine prema vremenskom horizontu: vrlo kratko, kratkoročno, srednjoročno te dugoročno. Vrlo kratko prognoziranje se odnosi na vremenski period od nekoliko minuta do jedan sat unaprijed, a koristi se za operacije upravljanja prijenosnom mrežom u stvarnom vremenu, regulatorne aktivnosti te vođenje unutardnevnog tržišta električnom energijom. Vremenska skala kratkoročnog predviđanja se odnosi na period od jednog sata do 6 sati unaprijed te se primjenjuje u svrhu ekonomske raspodjele opterećenja na agregate, odnosno predviđanja smanjenja ili povećanja opterećenja. Srednjoročna prognoza (6 sati – nekoliko dana) se koristi za odluke o upuštanjima generatora u pogon ili izvan pogona te za potrebe dan unaprijed tržišta električne energije. Konačno, dugoročna ili sezonska prognoza se odnosi na sve vremenske horizonte veće od jednog dana, a koristi se za planiranje regulatornih rezervi, planiranje održavanja te planiranje razvoja EES-a.

Statističke metode pružaju dobre rezultate u vrlo-kratkom i kratkoročnom prognoziranju, no značajan utjecaj atmosferske dinamike u za srednjoročno i dugoročno prognoziranje zahtijeva korištenje numeričkih meteoroloških modela. U tablici 2 prikazan je sažetak klasifikacije metoda prognoziranja prema vremenskom horizontu i njihove primjene [54].

Tablica 2. Klasifikacija prognoza po vremenskom horizontu, prema [54]

	Vrsta prognoze	Horizont	Primjene	Metode
Prognoza proizvodnje	Vrlo kratka (unutar-satna)	5-60 min	Regulacija, dispečiranje u stvarnom vremenu, zatvaranje tržišta EE	Statističke, ustrajnost <sup>3</sup>
	Kratkoročna	1-6 sati	Promjene opterećenja elektrana, upravljanje zagušenjima	Statističke i fizikalne metode
	Srednjoročna	6 sati-nekoliko dana	Planiranje opterećenja i rezervi, vođenje dan-unaprijed tržišta EE	Uglavnom fizikalne s korekcijama sistematičkih pogreški
	Dugoročna	Tjedne, sezonske, godišnje	Planiranje resursa, analiza neplaniranih događaja, planiranje održavanja (remonta) i nadogradnje EES-a	Klimatološke prognoze, fizikalni modeli
Potpora odlučivanju	Ramp forecasting	Kontinuirano	Vođenje sustava, redukcija proizvodnje	Fizikalne i statističke
	Prognoza potrošnje	Unutar-satna, sat-unaprijed, dan-unaprijed	Upravljanje zagušenjima, upravljanje potrošnjom	Statističke

### Točnost prognoze


Konvencionalno prognoziranje proizvodnje iz VE producira vrijednost u nekom budućem trenutku (deterministički pristup). Ipak, svaka prognoza u sebi inherentno sadrži i određeni dio nesigurnosti. Stoga, probabilističko pristup, uz prognoziranje vrijednosti, dodatno pruža i kvantitativnu mjeru pouzdanosti izlaznih podataka. Probabilističke metode koje računavaju mjeru pouzdanosti klasificiraju se u tri kategorije prema obliku pouzdanosti: vjerojatnosnu, temeljenu na riziku (eng. risk-based) te prostorno-vremensko (eng. space-time) prognoziranje.

<sup>3</sup> Ustrajnost (eng. persistence) je najjednostavnija metoda prognoziranja koja pretpostavlja da će uvjeti u trenutku prognoze

Vjerojatnosne prognoze se obično prikazuju u obliku grafičkih intervala pouzdanosti oko prognoziranih vrijednosti [Slika 4]. Parametarski i neparametarski pristup su dvije glavne metode za konstrukciju razdiobe prognoze. Parametarski pristup podrazumijeva da prediktivna distribucija slijedi unaprijed definirani oblik koji se može opisati analitičkim izrazom. Primjer parametarskog pristupa je Gaussova razdioba koja se može potpuno opisati pomoću parametara standardne devijacije i očekivanja. Za razliku od parametarskog pristupa, neparametarski pristup ne podrazumijeva unaprijed definirani oblik razdiobe. PDF i CDF funkcije se dobivaju interpolacijom na konačnom broju točaka. Neparametarske metode korištene za analize pouzdanosti predviđanja iz VE su KDE metoda (eng. Kernel Density Estimation) temeljena na funkciji gustoće razdiobe te kvantilna regresija (eng. Quantile Regression-QR) [55].

Drugi način prikazivanja pouzdanosti rezultata prognoziranja je pomoću indeksa rizika. Indeks rizika se može definirati kao očekivani stupanj točnosti rezultata. Stoga, veća vrijednost indeksa rizika znači manje pouzdane rezultate prognoza. Stupanj rizika se često grafički prikazuje pomoću različitih boja koje sugeriraju različite skupine pouzdanosti rezultata. U slučaju visokog indeksa rizika, potrebne su preventivne mjere za smanjenje potencijalnog rizika uzrokovanog pogrešnom prognozom (npr. povećanje kapaciteta rezervi) [56].

Osim navedenih pristupa u literaturi se može pronaći tzv. prostorno-vremensko predviđanje (eng. Space-time scenario forecasting) [57]. Vremenska korelacija proizvodnje iz vjetroelektrana se može modelirati pomoću kombiniranih PDF krivulja. Ipak, zbog nepraktičnosti korištenja kombiniranih PDF krivulja za donošenje odluka, uvodi se pojam scenarija koji su prikladni za rješavanje stohastičkih optimizacijskih problema za donošenja odluka u vođenju EES-a. Probabilističko predviđanje proizvodnje za svaku vjetroelektranu generira se neovisno za svaki budući trenutak. Ipak, računanje vremenske i prostorne korelacije u vjerojatnosne analize nužno je za opisivanje dinamičkih promjena pouzdanosti izlaznih rezultata. Kako bi pouzdanost rezultata predikcije bila što točnija, potrebno je generirati veliki broj scenarija pomoću Monte Carlo simulacija što povećava računalne zahtjeve i vrijeme proračuna. Sve metode se pokazuju uspješnima, ali uspjehnost svake metode uvelike ovisi o kvaliteti i dostupnosti podataka.



Slika 4: Intervali pouzdanosti prognoze, izvor [54]

biti jednaki trenutnima, odnosno da se neće promijeniti. Često se koristi za vrednovanje ostalih prognostičkih metoda.

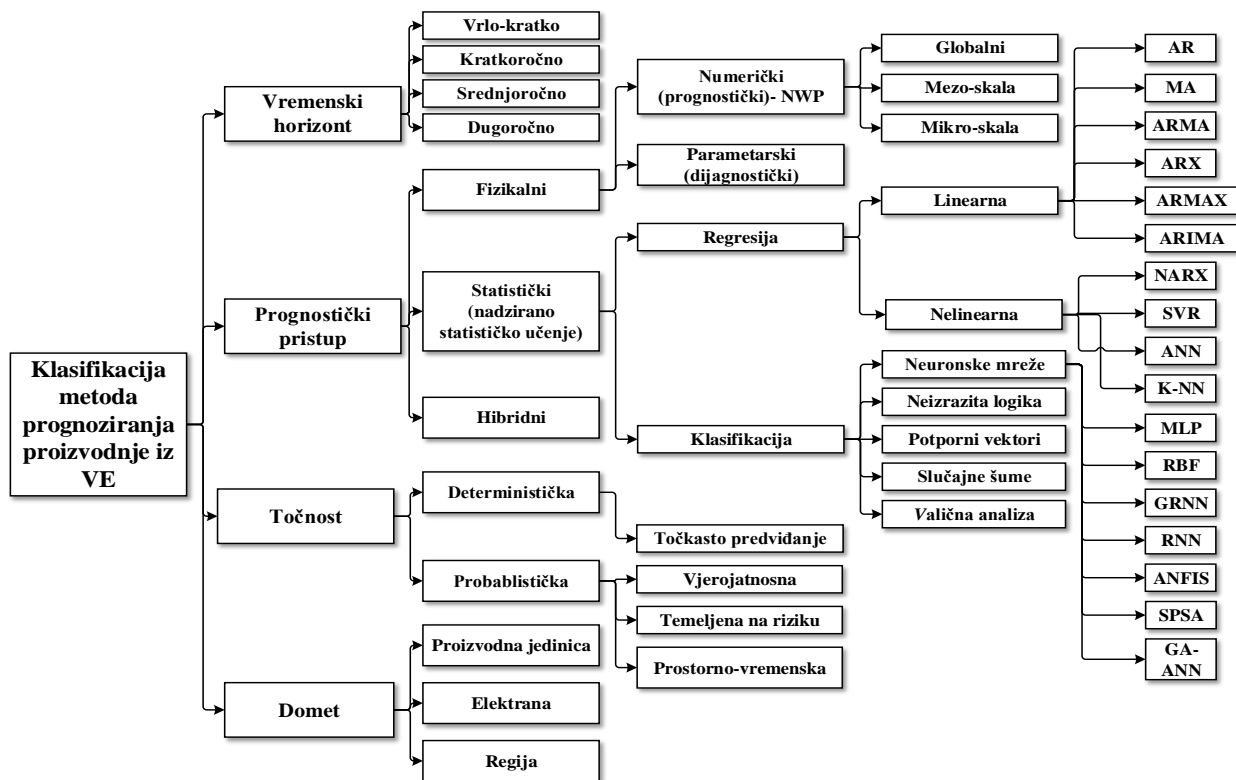
## Domet prognoze

Ovisno o dostupnosti mjerenih podataka, proizvodnja se može prognozirati za jednu proizvodnu jedinicu, elektranu ili regiju. Tipično, prostorna korelacija predviđanja proizvodnje, za elektrane koje nemaju dovoljan broj mjernih uređaja, radi se na temelju podataka iz susjednih elektrana. Često korištena metoda prostorne korelacije je mjerenje-korelacija-predviđanje (eng. Measure-Correlate-Predict-MCP) metoda koja se koristi za studije budućih integracija vjetroelektrana. Metoda se koristi za prikupljanje dugoročnih podataka o vjetru na razmatranoj lokaciji prema podacima sa referentne lokacije. Razrađene su četiri MCP metode: linearna regresija, matricna MCP metoda, Weibullova skala te Wind index MCP model [58].

Prognožiranje proizvodnje na većim područjima s većim brojem instaliranih vjetroelektrana obično se ostvaruje na

način da se prognozira proizvodnja samo nekoliko vjetroelektrana te se izlazni rezultat ekstrapolira na cijelu regiju (eng. regional upscaling). Na taj se način olakšava prognoza na velikim područjima te se smanjuje količina podataka iz NWP modela. Točnost takvog načina predviđanja se ne smanjuje znatno jer susjedne vjetroelektrane pokazuju slične obrasce proizvodnje. Grupno predviđanje proizvodnje vjetroelektrana često daje točnije rezultate zbog poništavanja fluktuacija proizvodnje na pojedinim lokacijama (eng. smoothing effect). Osim ekstrapolacija na veću regiju, moguće je i silazno skaliranje podataka na pojedine lokacije (eng. downscaling) prema regionalnim prognozama.

Na slici 4 prikazan je pregled klasifikacija metoda prognožiranja proizvodnje.



Slika 5: Klasifikacija metoda prognožiranja proizvodnje iz VE

## F. Mjere točnosti metoda

Značajke svakog od modela uspoređuju se na temelju mjera (metrike) točnosti rezultata. U većini literature koriste se klasične statističke mjere točnosti kao što su:

- Srednja pogreška prognoze (eng. Forecast bias):

$$BIAS = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_i') \quad (5)$$

gdje  $Y_i$  predstavlja  $i$ -tu mjerenu vrijednost,  $Y_i'$  prognoziranu, dok  $n$  predstavlja ukupan broj prognostičkih grešaka. Zbog poništavanja pozitivnih i negativnih grešaka, navedena mjera ne pokazuje stvarnu točnost prognoze.

- Srednja kvadratna pogreška (eng. Mean Square Error-MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_i')^2 \quad (6)$$

Navedena mjera pogodna je za identifikaciju većih pojedinačnih prognostičkih odstupanja.

- Korijen srednje kvadratne pogreške (eng. Root Mean Square Error-RMSE):

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y_i')^2} \quad (7)$$

RMSE je najčešće korištena mjera točnosti.



- Standardna greška (eng. Standard Deviation of Errors-SDE):

$$SDE = \frac{s}{\sqrt{n}} \quad (8)$$

gdje  $s$  predstavlja korijen prosječne kvadratne devijacije od aritmetičke sredine uzoraka  $X$  :

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{X})^2}{n - 1} \quad (9)$$

Osim navedenih mjera točnosti u literaturi se mogu pronaći metrike koje pokušavaju na prikladniji način opisati utjecaj različitih vremenskih horizonata, geografskih lokacija itd. Neke od novijih mjera točnosti su [24]:

- Srednja apsolutna skalirana pogreška (eng. Mean Absolute Scaled Error-MASE);
- Srednja apsolutna devijacija intervala (eng. Mean Absolute Interval Deviation-MAID).

Navedene mjere mogu relativno dobro usporediti učinkovitost pojedinih metoda, no potrebno je razmotriti dodatne čimbenike koji bitno utječu na rezultate prognozirivanja. Primjerice, pri usporedbi točnosti metoda za prognozu proizvodnje iz solarnih elektrana i vjetroelektrana značajnu ulogu imaju varijabilnost klime i topografija terena na razmatranom području, tj. potrebno je usporediti istu metodu na različitim područjima kako bi se ocijenila robusnost modela. Dodatno, bitnu ulogu ima usrednjavanje rezultata koje na većim vremenskim periodima vodi do manjih pogrešaka. Također, bitna je i prostorna komponenta predikcije s obzirom da je nemoguće uspoređivati modele za regionalnu proizvodnju s modelima za prognozu proizvodnje pojedine elektrane. Uz to, vrijeme ispitivanja modela te specifičnosti svake od pojedinih lokacija dodatno otežavaju usporedbe.

#### G. Zahtjevi prema naprednim prognostičkim metodama

Buduće napredne metode prognozirivanja proizvodnje temeljit će se na metodama prezentiranim u radu, a obuhvaćat će napredak u fizikalnim i statističkim postupcima, kao i u njihovim raznim kombinacijama u obliku hibridnih metoda u svrhu smanjenja prognostičke pogreške. Razvoj će obuhvaćati:

- Proširenje vremenskog horizonta prognoze za potrebe dugoročnih planiranja;
- Detekciju ekstremnih vremenskih nepogoda u svrhu povećanja sigurnosti rada EES-a.
- Unaprjeđenje kvalitete nadmetanja na tržištu EE i pomoćnim uslugama u svrhu maksimizacije dobiti od strane proizvođača.
- Unaprjeđenje automatskog prilagođavanja modela za primjenu na različitim lokacijama koji će bolje uzimati u obzir lokalne atmosferske prilike i složenu orografiju tla.


Značajnu ulogu u razvoju metoda prognozirivanja proizvodnje imat će razvoj modela za pučinske (eng. offshore) vjetroelektrane koje uglavnom koriste modele prilagođene elektranama na kopnu (eng. onshore). Meteorološke prilike u niskim atmosferskim slojevima blizu obale razlikuju se od onih na obali u tri pogleda: nelinearna interakcija vjetera i valova uzrokuje varijabilnu, ali nisku hrapavost terena; veliki toplinski kapacitet vode mijenja prostorno-vremensku karakteristiku termalne stratifikacije; atmosferski tokovi su drugačiji zbog diskontinuiteta na prijelazu s mora na kopno

[59]. Zbog toga, potrebno je razviti modele prilagođene navedenim atmosferskim prilikama kako bi se unaprijedilo prognoziranje proizvodnje pučinskih vjetroelektrana, jer se očekuje da će glavnina budućih instaliranih vjetroturbina biti postavljena na moru.

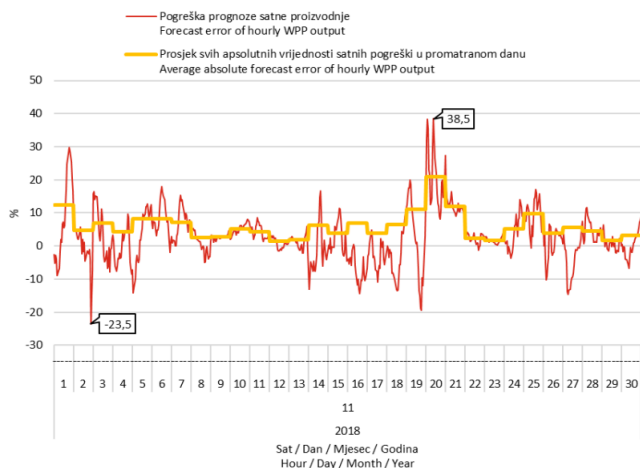
### III. PROGNOZIRANJE PROIZVODNJE IZ VE U HRVATSKOJ

Prognoza proizvodnje iz VE, za potrebe vođenja EES-a, u Hrvatskoj je započela 2011. godine, a provodio ju je i unaprijeđivao HOPS. Promjenom zakonskih okvira, odgovornost za provođenje prognoze trebala bi preći na Hrvatskog operatora tržišta energije (HROTE) kao voditelja EKO bilančne grupe [60].

Za potrebe kratkoročnog i srednjoročnog prognozirivanja proizvodnje iz VE u Hrvatskoj, koriste se tri odvojena prognostička alata s jezgama koje koriste aspekte fizikalnih i statističkih procedura za prognoziranje proizvodnje: WPPT (eng. Wind Power Prediction Tool), WPMS (eng. Wind Power Management System) te AIOLOS. Ulazne meteorološke podatke pruža NWP model ALADIN (fra. Aire Limitée Adaptation Dynamique développement InterNational) koji pruža podatke o brzini i smjeru vjetera 72 sata unaprijed, vremenske rezolucije od jednog sata te četiri puta dnevno s horizontalnom rezolucijom od 2 km [61]. Zbog učinkovitijeg prognozirivanja proizvodnje, navedeni alati su objedinjeni u jedan sustav pomoću kojeg se proračunava optimalna prognostička krivuljana na temelju meteoroloških podataka i ostvarene proizvodnje iz vjetroelektrana. Pojedinom prognostičkom modelu se pridružuju težinski faktori kako bi se odredila ponderirana aritmetička sredina kao konačna prognoza proizvodnje. Korištena mjera točnosti prognoze je korijen srednje kvadratne pogreške (RMSE). Na slici 9 prikazano je kretanje točnosti prognoze od 2012. do 2015. godine, pomoću korijena srednje kvadratne pogreške prognoze (RMSE). Prema navedenim podacima, može se uočiti poboljšanje točnosti prognoza, no apsolutne satne i dnevne pogreške prognoze mogu dosegnuti visoke vrijednosti. Na slici 10 prikazane su apsolutne satne i prosječne dnevne pogreške proizvodnje u studenom 2018. u postocima instalirane snage VE. Najviša pozitivna satna pogreška (prognoza veća od ostvarenja) iznosila je 38,5% od ukupnog kapaciteta iznosa, dok je najniža iznosila -23,5%. Uzimajući u obzir ukupni instalirani kapacitet VE za navedeni period (576 MW), potrebna energija uravnoteženja može dosegnuti relativno visoke vrijednosti zbog velikih prognostičkih grešaka.



Slika 6: Godišnji RMSE u RH [61]



Slika 7: Apsolutne satne i dnevne pogreške proizvodnje svih VE u studenom 2018.

#### IV. ZAKLJUČAK

U radu je predstavljen pregled i klasifikacija metoda za prognoziranje proizvodnje iz VE. Metode su podijeljene prema četiri kriterija: vremenskom horizontu, modelu predviđanja, točnosti i dometu. Statistički pristup prognoziranju, koji uključuje klasične i napredne metode (umjetna inteligencija) regresije i klasifikacije, zahtijeva veliku količinu povijesnih ulaznih podataka. Konvencionalni statistički modeli su primarno predviđeni za vrlo kratko i kratkoročno predviđanje, metode s elementima umjetne inteligencije su u mogućnosti modelirati složene nelinearne ulazno-izlazne odnose podataka kroz učenje i treniranje. Iskorištavanje prednosti pojedinih metoda kroz hibridni pristup često daje izvrsne rezultate (npr. ANN-Fuzzy). Prikazani su osnovni koncepti analize i prognoziranja vremenskih serija. Konačno prikazan je način i učinkovitost prognoziranja proizvodnje iz VE u Hrvatskoj.

Nastavak istraživanja će se bazirati na razvoju novih i unaprijeđenju postojećih fizikalnih i statističkih metoda kratkoročnog prognoziranja sa elementima strojnog učenja. Razmotrit će se važnost naprednih prognoza u elektroenergetskim sustavima niske inercije. Metode će se razvijati na temelju stvarnih povijesnih mjerenja i meteoroloških prognoza sa lokacija postojećih VE u Hrvatskoj.

#### ZAHVALA

Istraživanje je provedeno u sklopu projekta WINDLIPS – WIND energy integration in Low Inertia Power System Hrvatske zaklade za znanost, br. 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] K. Jurkovic, H. Pandžić and 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.
- [4] G. Boyle, *Renewable electricity and the grid: The challenge of variability*, London, UK: Earthscan Publications Ltd., 2012.
- [5] S. Tešnjak, E. Banovac and I. Kuzle, *Tržište električne energije*, Zagreb: Graphis, 2009.
- [6] National Renewable Energy Laboratory, *The Value of Improved Short-Term Wind Power Forecasting*, NREL, February 2015.
- [7] I. Okumus and A. Dinler, "Current status of wind energy forecasting and a hybrid method for hourly predictions," *Energy Conversion and Management*, vol. 123, pp. 362-371, 2016.
- [8] C. Gallego-Castillo, A. Cuerva-Tejero and O. Lopez-Garcia, "A review on the recent history of wind power ramp forecasting," *Renewable and Sustainable Energy Reviews*, vol. 52, pp. 1148-1157, December 2015.
- [9] J. Zhang, M. Cui, B.-M. Hodge, A. Florita and J. Freedman, "Ramp forecasting performance from improved short-term wind power forecasting over multiple spatial and temporal scales," *Energy*, vol. 122, pp. 528-541, 2017.
- [10] A. Tascikaraoglu and M. Uzunoglu, "A review of combined approaches for prediction of short-term," *Renewable and Sustainable Energy Reviews*, vol. 34, pp. 243-254, 2014.
- [11] R. H. Shumway and D. S. Stoffer, *Time Series Analysis and Its Applications*, Springer, 2011.
- [12] R. J. Hyndman i G. Athanasopoulos, »Forecasting: Principles and Practice,« Monash University, Australia, April 2018. [Mrežno]. Available: <https://otexts.com/fpp2/>. [Pokušaj pristupa 2019].
- [13] I. Colak, S. Sagioglu, M. Yesilbudak, E. Kabalci and H. I. Bulbul, "Multi-time series and -time scale modeling for wind speed and wind power forecasting part I: Statistical methods, very short-term and short-term applications," in *International Conference on Renewable Energy Research and Applications (ICRERA)*, Palermo, Italy, 2015.
- [14] I. Ç. Serkan Buhan, "Multistage Wind-Electric Power Forecast by Using a Combination of Advanced Statistical Methods," *IEEE Transactions on Industrial Informatics*, vol. 11, no. 5, pp. 1231-1242, 2015.
- [15] P. Gomes and R. Castro, "Comparison of statistical wind speed forecasting models," in *World Congress on Sustainable Technologies (WCST)*, London, UK, 2011.
- [16] NCSS Statistical Software, [Online]. Available: [https://ncss-wpengine.netdna-ssl.com/wp-content/themes/ncss/pdf/Procedures/NCSS/The\\_Box-Jenkins\\_Method.pdf](https://ncss-wpengine.netdna-ssl.com/wp-content/themes/ncss/pdf/Procedures/NCSS/The_Box-Jenkins_Method.pdf). [Accessed 2019].
- [17] S. Tian, Y. Fu, P. Ling, S. Wei, S. Liu and K. Li, "Wind Power Forecasting Based on ARIMA-LGARCH Model," in *International Conference on Power System Technology (POWERCON)*, Guangzhou, China, 2018.
- [18] J. Palomares-Salas, J. G. d. I. Rosa, J. Ramiro, J. Melgar, A. Aguera and A. Moreno, "ARIMA vs.

- Neural networks for wind speed forecasting," in *IEEE International Conference on Computational Intelligence for Measurement Systems and Applications*, Hong Kong, China, 2009.
- [19] F. A. Eldali, T. M. Hansen, S. Suryanarayanan and E. K. P. Chong, "Employing ARIMA models to improve wind power forecasts: A case study in ERCOT," in *North American Power Symposium (NAPS)*, Denver, CO, USA, 2016.
- [20] W. Meng-Di, Q.-R. Q. and B.-W. C, "Short-term wind speed forecasting combined time series method and arch model," in *Proceedings of the 2012 international conference on machine learning and cybernetics (ICMLC)*, 2012.
- [21] H. Chen, Q. Wan, F. Li and Y. Wang, "GARCH in mean type models for wind power forecasting," in *IEEE Power & Energy Society General Meeting*, Vancouver, BC, Canada, 2013.
- [22] Y. Lin, U. Kruger, J. Zhang, Q. Wang, L. Lamont and L. E. Chaar, "Seasonal Analysis and Prediction of Wind Energy Using Random Forests and ARX Model Structures," *IEEE Transactions on Control Systems Technology*, vol. 23, no. 5, pp. 1994 - 2002, 2015.
- [23] E. Zhao, J. Zhao, L. Liu, Z. Su and N. An, "Hybrid Wind Speed Prediction Based on a Self-Adaptive ARIMAX Model with an Exogenous WRF Simulation," *Energies*, vol. 9(1), p. 7, 2015.
- [24] T. Nielsen, H.As.Nielsen and H. Madsen, "Prediction of wind power using time-varying coefficient-functions," in *15th Triennial World Congress*, Barcelona, Spain, 2002.
- [25] M. S. Miranda and R. W. Dunn, "One-hour-ahead Wind Speed Prediction Using a Bayesian Methodology," in *IEEE power engineering society general meeting*, 2006.
- [26] T. Plavšić and I. Kuzle, "Artificial Neural Networks Applications in Power Systems," in *40th International Symposium ELMAR*, Zadar, Croatia, 1998.
- [27] G. Zhang, B. Patuwo and M. Y. Hu, "Forecasting with artificial neural networks: the state of the art," *Int. J. Forecast*, vol. 14(1), pp. 35-62, 1998.
- [28] E. B. Ssekulima, M. B. Anwar, A. A. Hinai i M. S. E. Moursi, »Wind speed and solar irradiance forecasting techniques for enhanced renewable energy integration with the grid: a review,« *IET Renewable Power Generation*, svez. 10(7), pp. 885-989, 2016.
- [29] K. Bhaskar and S. N. Singh, "AWNN-Assisted Wind Power Forecasting Using Feed-Forward Neural Network," *IEEE Transactions on Sustainable Energy*, vol. 3, no. 2, pp. 306-315, 2012.
- [30] V. Jain, A. Singh, V. Chauhan and A. Pandey, "Analytical study of Wind power prediction system by using Feed Forward Neural Network," in *International Conference on Computation of Power, Energy Information and Commuincation (ICCPEIC)*, Chennai, India, 2016.
- [31] M. A. Mohandes, T. O. Halawani, S. Rehman and A. A. Hussain, "Support vector machines for wind speed prediction," *Renewable Energy*, vol. 29, p. 939–947, 2004.
- [32] L. Xingpei, L. Yibing and X. Weidong, "Wind speed prediction based on genetic neural network," in *4th IEEE Conf. on Industrial Electronics and Applications*, 2009.
- [33] R. Jursa, "Proc. Ninth Annual Conf. on Genetic and Evolutionary," 2007.
- [34] J. Đaković and I. Kuzle, "Status i klasifikacija metoda za prognoziranje proizvodnje električne energije iz vjetroelektrana," in *13. Simpozij o sustavu vođenja EES-a*, Rovinj, Hrvatska, 2018.
- [35] K. A, H. Z and S. Z., "Short-term prediction of wind farm power: a data mining approach," *IEEE TransactionsonEnergyConversions*, vol. 24(1), pp. 125-136, 2009.
- [36] Z. Zhu, D. Zhou and Z. Fan, "Short term forecast of wind power generation based on SVM with pattern matching," in *IEEE International Energy Conference (ENERGYCON)*, Leuven, Belgium, 2016.
- [37] J. Wang, J. Sun and H. Zhang, "Short-term wind power forecasting based on support vector machine," in *5th International Conference on Power Electronics Systems and Applications(PESA)*, Hong Kong, China, 2013.
- [38] T. Pinto, S. Ramos, T. M. Sousa and Z. Vale, "Short-term wind speed forecasting using Support Vector Machines," in *IEEE Symposium on Computational Intelligence in Dynamic and Uncertain Environments (CIDUE)*, Orlando, FL, USA, 2014.
- [39] A. Lahouar and J. B. H. Slama, "Hour-ahead wind power forecast based on random forests," *Renewable Energy*, vol. 109, pp. 529-541, August 2017.
- [40] W. Shen, N. Jiang and N. Li, "An EMD-RF Based Short-term Wind Power Forecasting Method," in *IEEE 7th Data Driven Control and Learning Systems Conference (DDCLS)*, Enshi, China, 2018.
- [41] T. Joo and S. Kim, "Time series forecasting based on wavelet filtering," *Expert Systems with Applications*, vol. 42, no. 1, p. 3868–3874, 2015.
- [42] A. A. Khan and M. Shahidehpour, "One day ahead wind speed forecasting using wavelets," in *IEEE/PES Power Systems Conference and Exposition*, Seattle, WA, USA, 2009.
- [43] Y. Liu, D.-l. Zeng, J.-z. Liu, J.-w. Liu, H.-q. Guo and Y.-m. Liu, "Short-term wind speed forecast based on wavelet packet transform and LS-SVM," in *24th Chinese Control and Decision Conference (CCDC)*, Taiyuan, China, 2012.
- [44] T. Howard and P. Clark, "Correction and downscaling of NWP wind speed forecasts," *Meteorol. Appl.*, vol. 14, p. 105–116, 2007.
- [45] M. Lange and U. Focken, *Physical approach to short-term wind power prediction*, New York: Springer, 2006.
- [46] Risø National Laboratory , *Wind Power Prediction using Ensembles*, DTU, 2005.
- [47] L. Landberg, "Short-term prediction of the power production from wind farms," *J. Wind Engg. Ind. Aerodyn*, vol. 80, no. 207, 1999.

- [48] W.-Y. Chang, "A Literature Review of Wind Forecasting Methods," *Journal of Power and Energy Engineering*, vol. 2, pp. 161-168, 2014.
- [49] B. H. and B. N.: "Multiple architecture system for wind speed prediction," *Applied Energy*, vol. 88, no. 7, p. 2463–2471, July 2011.
- [50] G. W. Chang, H. J. Lu, L. Y. Hsu and Y. Y. Chen, "A hybrid model for forecasting wind speed and wind power generation," in *IEEE Power and Energy Society General Meeting (PESGM)*, Boston, MA, USA, 2016.
- [51] Z. Hui, L. Bin and Z. Zhuo-qun, "Short-term wind speed forecasting simulation research based on ARIMA-LSSVM combination method," in *International Conference on Materials for Renewable Energy & Environment*, Shanghai, China, 2011.
- [52] P. Zhao, J. Wang, J. Xia, Y. Dai, Y. Sheng and J. Yue, "Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China," *Renewable Energy*, vol. 43, pp. 234-241, 2012.
- [53] T. Nielsen, H. Madsen, H. A. Nielsen, L. Landberg and G. Giebel, "Zephyr-The Prediction Models," in *European Wind Energy Conference*, Copenhagen, 2001.
- [54] B. O'Neill, *Forecasting Wind (Presentation) - NREL*, Raleigh, North Carolina: Presented to the Southeastern Wind Coalition UAG Forecasting and Integration Meeting, 2016.
- [55] Y. Zhang, J. Wang and X. Wang, "Review on probabilistic forecasting of wind power generation," *Renewable and Sustainable Energy Reviews*, vol. 32, p. 255–270, 2014.
- [56] X. Li and H. Wang, "Operation risk assessment of wind farm integrated system influenced by weather conditions," in *IEEE Power & Energy Society General Meeting*, Vancouver, BC, Canada, 2013.
- [57] J. Bessac, E. Constantinescu and M. Anitescu, "Stochastic simulation of predictive space-time scenarios of wind speed using observations and physical models," *Annals of Applied Statistics*, 2016.
- [58] C. J. R. Sheppard, *Analysis of the measure-correlate-predict methodology for wind resource assessment*, A Thesis Presented to The Faculty of Humboldt State University, 2009.
- [59] J. Tambke, L. v. Bremen, R. Barthelmie, A. Palomares and T. Ranchin, "Short-term Forecasting of Offshore Wind Farm Production – Developments of the Anemos Project," in *European Wind Energy Conference*, Athènes, Greece, 2006.
- [60] Hrvatski operator prijenosnog sustava d.o.o., "Mjesečni izvještaj o proizvodnji vjetroelektrana u Hrvatskoj," 2018.
- [61] Hrvatski operator prijenosnog sustava d.o.o., "Proizvodnja VE - planovi i ostvarenja u proteklih 15 mjeseci," 2016.
- [62] A. M. Foley, P. G. Leahy, A. Marvuglia and E. J. McKeogh, "Current methods and advances in forecasting of wind power generation," *Renewable Energy*, vol. 37, pp. 1-8, January 2012.
- [63] R. S. F. Ferraz, R. S. F. Ferraz and F. C. Cruz, "Multi step forecasting of the wind generation by ARIMA and k-NN," in *Simposio Brasileiro de Sistemas Eletricos (SBSE)*, Niteroi, Brazil, 2018.
- [64] Y. Lin, U. Kruger, J. Zhang, Q. Wang, L. Lamont and L. E. Chaar, "Seasonal Analysis and Prediction of Wind Energy Using Random Forests and ARX Model Structures," *IEEE Transactions on Control Systems Technology*, vol. 23, no. 5, pp. 1994 - 2002, 2015.
- [65] "Vrijeme i klima hrvatskog Jadrana," [Online]. Available: [http://jadrana.gfz.hr/pojmovnik\\_s.html#struktura\\_a](http://jadrana.gfz.hr/pojmovnik_s.html#struktura_a). [Accessed 2019].