

MOŻLIWOŚCI POPRAWY JAKOŚCI PROGNOZ GENERACJI WIATROWEJ PRZY WYKORZYSTANIU DOSTĘPNYCH INFORMACJI JAKO ZMIENNYCH OBJAŚNIAJĄCYCH

Rafał MAGULSKI¹, Tomasz PAKULSKI²

1. Instytut Energetyki Instytut Badawczy Oddział Gdańsk
tel.: 58 349 82 11; fax: 58 341 76 85; e-mail: r.magulski@ien.gda.pl
2. Instytut Energetyki Instytut Badawczy Oddział Gdańsk
tel.: 58 349 82 11; fax: 58 341 76 85; e-mail: t.pakulski@ien.gda.pl

Streszczenie: W artykule przedstawiono wyniki analiz dotyczących możliwości prognozowania generacji wybranej farmy wiatrowej (FW), realizowanych za pomocą zróżnicowanych metod predykcyjnych, wykorzystujących odmienny zakres danych pomiarowych i prognostycznych, dostępnych na farmie i w jej otoczeniu. Analizy koncentrowały się na ocenie błędów uzyskiwanych prognoz oraz doborze danych wejściowych do modeli prognostycznych i ocenie ich wpływu na poprawę jakości predykcji.

Słowa kluczowe: prognozowanie, metody statystyczne, sieci neuronowe.

1. WSTĘP

Do korekt numerycznych prognoz pogody (NPP) na świecie najczęściej wykorzystywane są metody *ex post*, bazujące na danych historycznych. W literaturze najczęściej występującymi metodami korygowania numerycznych prognoz pogody są [1, 2, 3]:

- metody statystyczne, w których poszukuje się zależności opisujących związek zmiennych prognozowanych ze zmiennymi rzeczywistymi np. metody regresji;
- metody sztucznej inteligencji, w których w procesie uczenia wykorzystuje się korelację pomiędzy zmiennymi wejściowymi a zmienną wyjściową (oczekiwaną) np. sztuczne sieci neuronowe (SSN).

W ramach pracy było zbadanie możliwości korygowania NPP w celu poprawy jakości predykcji generacji wiatrowej w horyzoncie 24-godzinowym, przy wykorzystaniu obu przedstawionych metod [4].

Do wykonania symulacji wykorzystano historyczne dane z wybranej FW. Próbkę danych wejściowych licząca ok. 300 dni obejmowała: NPP, pomiar rzeczywistych warunków atmosferycznych oraz wielkość rzeczywistej produkcji farmy.

Poszukiwano rozwiązania dającego w rezultacie najmniejszy średni bezwzględny błąd prognozy produkcji farmy wiatrowej $NMAE^1$ określonego jako:

$$NMAE = \frac{MAE}{P_{FW}} \quad (1)$$

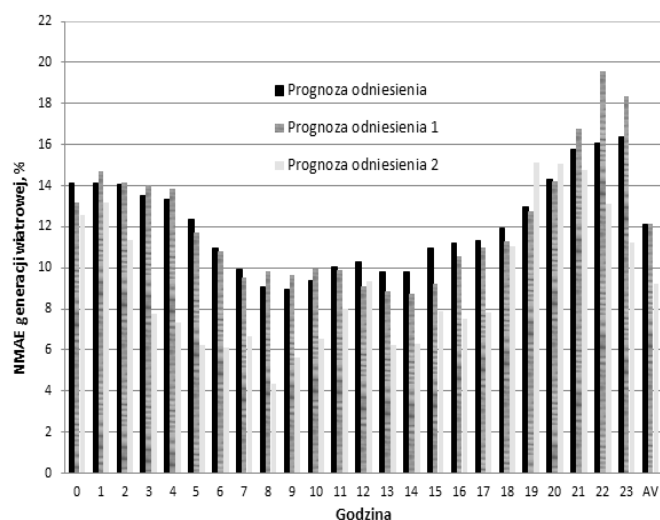
gdzie:

$$MAE = \frac{1}{N} \sum_{i=1}^N |PROG_1 - POM_1| \quad (2)$$

gdzie: P_{FW} – moc znamionowa farmy wiatrowej,
 $PROG_1$ – wartość prognozowana,
 POM_1 – wartość pomierzona (rzeczywista),
 N – liczba próbek.

Na podstawie NPP oraz krzywych mocy z poszczególnych turbin wyznaczono prognozę odniesienia produkcji farmy wiatrowej, a następnie błędy produkcji w poszczególnych godzinach doby (Prognoza odniesienia).

Zbiór danych testowych wykorzystanych do wykonania symulacji za pomocą SSN został wydzielony ze zbioru głównego w sposób przypadkowy (Prognoza odniesienia 1)². Zważywszy na losowy charakter wietrzności przedstawiony dobór pod kątem błędów generacji był reprezentatywny dla całego rozpatrywanego okresu (rys. 1). W celu sprawdzenia przydatności struktur, dla których otrzymano najmniejsze błędy dla prognozy odniesienia 1, przeprowadzono alternatywne symulacje dla prognozy odniesienia 2, w której testowy obejmował wybrany ciągle 14-dniowy okres roku³.



Rys. 1. Błędy prognoz odniesienia w poszczególnych godzinach

² Do testowania jakości nauczonej sieci wybrano 20% próbek z całego zbioru tj. co 5 dzień.

³ Dodatkowym celem przedstawionego podziału była możliwość porównania wyników obu rozpatrywanych metod.

¹ NMAE – Normalized mean absolute error

2. POPRAWA JAKOŚCI PROGNOZ GENERACJI POPRZEZ KOREKTĘ NUMERYCZNYCH PROGNOZ POGODY

2.1. Metody statystyczne

Dokonano analizy odchylenia prędkości wiatru zmierzonych na FW od wielkości prognozowanych, w szczególności badając wartość oraz stacjonarność średnich odchylenia. Stwierdzono, że średnie odchylenia wielkości prognozowanych od wartości rzeczywistych są niezerowe i mają zmienny charakter, w zależności od prognozowanej prędkości wiatru. Można stąd wnioskować, że odchylenia te wykazują pewną tendencję statystyczną, której usunięcie powinno prowadzić do zwiększenia trafności prognozy wiatru, a w konsekwencji do poprawy jakości prognozy generacji FW. Na tej podstawie zbudowano szereg modeli korekty prognozy wiatru, bazujących na metodzie regresji liniowej. Modele te wyznaczają zmianę wartości prognoz ex post w taki sposób, aby średnia ich odchylenia od wielkości zmierzonych zbliżona była do zera. W modelowaniu uwzględniono zróżnicowane okresy próbkowania danych do wyznaczania korekty, podział danych na klasy ze względu na porę doby i kierunek wiatru. Do dalszej analizy wybrano model, który w 14-dniowym okresie testowym osiągnął najmniejsze błędy prognoz prędkości wiatru.

2.2. Metody sztucznej inteligencji

Do wykonania symulacji wykorzystano pakiet obliczeniowy Neural Network w środowisku Matlab.

W ramach pracy testowano jednokierunkowe sieci zbudowane na wielowarstwowym perceptronie (MLP) według zaadoptowanego algorytmu przedstawionego w [5]. Przebadano wiele struktur sieci dwu oraz trójwarstwowych o zmiennej liczbie neuronów i funkcji aktywacji w poszczególnych warstwach, zróżnicowanych algorytmów uczących oraz zmiennej ilości cykli iteracyjnych [6, 7].

W rozważanym wariancie korekta prognoz produkcji była wykonywana w sposób dwuetapowy (model kaskadowy) [8]. W pierwszym etapie dokonywano korekty NPP, które wykorzystywano do wyznaczenia skorygowanych prognoz produkcji farmy. Rozpatrzono:

- wariant A – korekta poszczególnych zmiennych tworzących NPP;
- wariant B – wspólna korekta NPP⁴⁾.

Symulacje przeprowadzono oddzielnie dla każdej godziny doby i wybierano strukturę dla której otrzymano najmniejsze błędy odwzorowania.

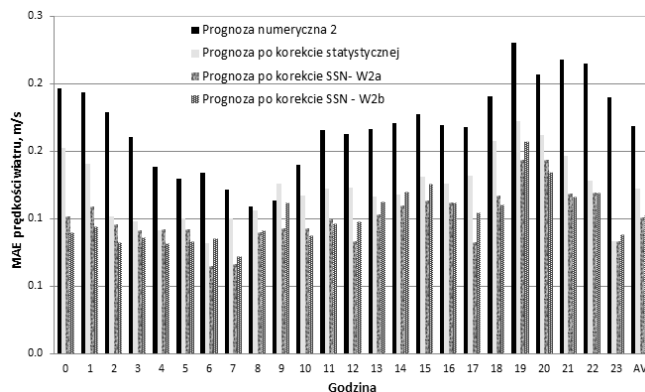
2.3. Porównanie wyników

Przedstawione wyniki (rys. 2) wskazują na dobową zmienność błędów prognoz. Badania wykazały, iż średnio możliwe jest zmniejszenie błędu MAE NPP o ok. 0,5 m/s, w przypadku metod statystycznych oraz o ok. 0,7 m/s w przypadku SSN⁵⁾.

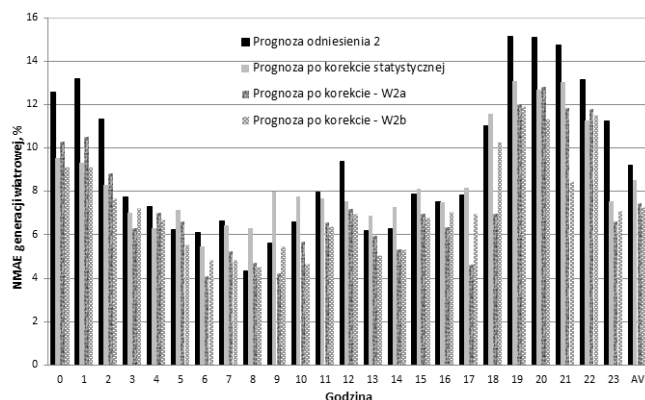
Błąd NMAE skorygowanej prognozy produkcji farmy wyznaczonej w oparciu o skorygowane NPP (rys. 3) zmniejsz

szyl się w stosunku do prognozy odniesienia w zależności od godziny doby:

- metody statystyczne: od -2,4% do 3,9% – średniodobowo o ok. 0,7%.
- sztuczne sieci neuronowe: od -0,1% do 6,3% – średniodobowo o ok. 2,0%⁶⁾.



Rys. 2. Korekta numerycznych prognoz pogody



Rys. 3. Korekta generacji wiatrowej przy wykorzystaniu skorygowanych prognoz numerycznych

Dla wybranego modelu regresji do korekty prognozy pogody średniodobowy błąd prognozy prędkości wiatru wyniósł 1,2 m/s, co oznacza poprawę o ok. 0,5 m/s w stosunku do prognozy odniesienia. Błąd NMAE prognozy generacji po zastosowaniu korekty statystycznej kształtował się na poziomie 8,5%, czyli był o ok. 0,7% niższy w stosunku do prognozy odniesienia. Wyniki uzyskane przy wykorzystaniu sztucznych sieci neuronowych zestawiono w tabeli 1.

Tabela 1. Korekta numerycznych prognoz pogody oraz generacji wiatrowej

Cecha	Średniodobowy błąd prognozy numerycznej MAE, m/s		Średniodobowy błąd generacji wiatrowej, NMAE, %	
	Prognoza numeryczna 1	Prognoza numeryczna 2	Prognoza odniesienia 1	Prognoza odniesienia 2
Wybór struktur dających najmniejszy błąd dla poszczególnych godzin doby				
Wartość przed korektą	1,71	1,69	12,2	9,2
Wartość po korekcie	1,33	1,02	10,7	7,2
Redukcja błędu prognozy	0,38	0,67	1,5	2,0
Wybór struktury dającej najmniejszy błąd w okresie całodobowym				
Wartość przed korektą	1,71	1,69	12,2	9,2
Wartość po korekcie	1,38	1,21	11,3	8,9
Redukcja błędu prognozy	0,33	0,48	0,9	0,3

⁴⁾ Przedstawione na rys. 2 oraz rys. 3. wartości błędów prognoz w poszczególnych godzinach dotyczą struktur dla których uzyskano najmniejszy błąd odwzorowania. AV – wartość średniodobowa. Wykorzystano sieci wielowarstwowe.

⁵⁾ Dla wariantów W2a i W2b SSN uzyskano zbliżone wyniki.

⁶⁾ W przypadku symulacji wykonanych dla prognozy odniesienia 2


3. KOREKTA PROGNOZ GENERACJI WIATROWEJ POPRZEZ WYKORZYSTANIE INFORMACJI O RZECZYWISTEJ PRODUKCJI

3.1. Metody statystyczne


Na podstawie historycznych pomiarów wiatru oraz mocy generowanej przez poszczególne turbiny dokonano aproksymacji rzeczywistej krzywej mocy FW w zależności od prędkości wiatru. Jak widać na rys. 4 uzyskana krzywa dość znacznie odbiega od krzywej wzorcowej przyjętej do sporządzenia prognozy odniesienia.

Do uwzględnienia w prognozie generacji strat energii wynikających z przesyłu i transformacji energii w obrębie FW wykorzystano sumaryczne dane o generacji poszczególnych turbin wiatrowych oraz informacje o ilości energii wprowadzanej do KSE, zmierzonej w punkcie przyłączenia FW. Za różnicę tych wielkości odpowiadają wewnętrzne straty elektryczne farmy. Dokonując aproksymacji krzywej na podstawie danych pomiarowych (rys. 5) określono zależność strat elektrycznych na farmie od prędkości wiatru. Na tej podstawie wyznaczano współczynnik korygujący energię brutto generowaną na poszczególnych masztach do postaci energii netto, wprowadzanej do sieci.

Wykorzystano informacje o statusie poszczególnych turbin wiatrowych. Dane historyczne o statusach turbin zostały przekształcone w taki sposób, aby mogły być traktowane jako sporządzona wcześniej prognoza dyspozycyjności farmy wiatrowej⁷⁾.



Rys. 4. Aproksymacja rzeczywistej krzywej mocy farmy wiatrowej



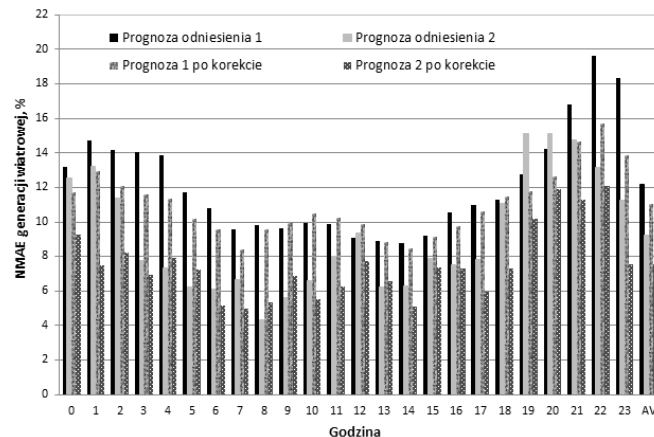
Rys. 5. Aproksymacja krzywej o straty mocy w obrębie FW

Punktem wyjścia do sporządzenia prognoz generacji FW były skorygowane prognozy wiatru, zgodnie z przyjętym modelem regresji liniowej. Wielkość generacji obliczono na podstawie uzyskanego przybliżenia rzeczywistej krzywej mocy FW, a następnie skorygowano ją o planowany wskaźnik dyspozycyjności farmy oraz wskaźnik strat elektrycznych na farmie.

⁷⁾ Pominięto informacje o wszelkich nieprzewidzianych przerwach w pracy turbin, a uwzględniono jedynie planowane postoje, związane z prowadzonymi przeglądami, konserwacjami lub remontami. Planowane ubytki mocy w generacji farmy wiatrowej mogą posłużyć do dokonania korekty prognozy produkcji.

3.2. Metody sztucznej inteligencji

W rozważanym wariancie (rys. 6) korekta prognoz produkcji była wykonywana bezpośrednio na podstawie NPP z wykorzystaniem danych historycznych o rzeczywistej produkcji farmy oraz statusie pracy poszczególnych turbin.




Rys. 6. Korekta generacji wiatrowej przy wykorzystaniu informacji o rzeczywistej produkcji

Wyniki symulacji przedstawionych na Rys.6. wskazują, iż możliwe jest zmniejszenie błędu MAE generacji wiatrowej w zależności od godziny doby w granicach⁸⁾:

- prognoza odniesienia 1: od $-0,8\%$ do $4,5\%$ – średniodobowo o $1,2\%$ z poziomu $12,2\%$ na $11,0\%$;
- prognoza odniesienia 2: od $-1,2\%$ do $5,7\%$ – średniodobowo o $1,7\%$ z poziomu $9,2\%$ na $7,5\%$.⁹⁾

4. PORÓWNANIE JAKOŚCI SKORYGOWANYCH PROGNOZ GENERACJI


Na rys. 7. przedstawiono porównanie błędów NMAE prognozy generacji wiatrowej w poszczególnych godzinach doby przed i po dokonaniu korekty, zaś na rys. 8 przebiegi generacji wiatrowej w symulowanym 14-dniowym okresie czasu.



Rys. 7. Błędy NMAE generacji wiatrowej przed i po dokonaniu korekt

⁸⁾ W przypadku przyjęcia struktur dających najmniejszy błąd prognozy dla poszczególnych godzin doby

⁹⁾ W przypadku przyjęcia struktury dającej najmniejszy NMAE w okresie całodobowym błąd prognozy wyniósł odpowiednio: $11,3\%$ (dla prognozy odniesienia 1) oraz $9,1\%$ (dla prognozy odniesienia 2)



Rys. 8. Przebiegi generacji wiatrowej w symulowanym 14-dniowym okresie czasu

5. PODSUMOWANIE I WNIOSKI

W pracy podjęto próbę poprawy jakości predykcji generacji wiatrowej poprzez korygowanie NPP przy użyciu metod statystycznych oraz metod sztucznej inteligencji. Badania wykazały:

- możliwość poprawy jakości prognozowania poprzez wykorzystanie metod sztucznej inteligencji w większym stopniu niż przy użyciu metod statystycznych;
- możliwość zmniejszenia błędu MAE NPP średniodobowo ok. 0,5 m/s (metody statystyczne) – 0,7 m/s (SSN);
- zmniejszenie średniodobowego błędu NMAE prognozy produkcji FW w zależności od prognozy odniesienia o ok. 1,5–2,0% (korekta 2-etapowa) oraz o ok. 1,2–1,7% (korekta 1-etapowa);
- zmniejszenie średniodobowego błędu NMAE produkcji FW wyznaczonej w oparciu o skorygowane prognozy wiatru przy użyciu metod regresji o ok. 0,4–0,7%;
- preferowanie wyboru różnych struktur neuronowych do korygowania prognoz w poszczególnych godzinach doby;
- składowe wykorzystane do określenia prognozy odniesienia miały tendencję do wzajemnego kompensowania

generowanych przez siebie błędów (prognozy prędkości wiatru prowadziły do niedoszacowania prognozy produkcji FW zaś skutkiem przyjęcia teoretycznej krzywej mocy było przeszacowanie produkcji), co działało na jej korzyść i mogło mieć wpływ na ograniczenie efektów zastosowanych narzędzi do poprawy jakości prognoz;

- konieczność ciągłej aktualizacji danych wejściowych, wykorzystywanych w procesie uczenia SSN. Wydłużenie okresu obserwacji pracy źródeł wiatrowych do okresu wielolecia pozwoli osiągnąć lepszą jakość predykcji.

6. BIBLIOGRAFIA

1. Sweeney C., Lynch P., Nolan P., Reducting errors of wind speed forecasts by an optimal combination of post-processing methods, Department of Meteorology and Climate Centre, Dublin, 2011.
2. Prondziński Z., Rubanowicz T., Zryczakowana usługa operatora handlowo – technicznego na potrzeby rozwoju energetyki wiatrowej w Polsce, *ActaEnergetica*, 2/19, 2004.
3. Sweeney C., Lynch P., Nolan P., Courtney J., Post-processing COSMO output for improved wind forecast, Meteorology and Climate Centre, Universtity College Dublin, Ireland, April 2012.
4. Selcuk Nogay H., Akinci T.C., Eidukeviciute M., Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey, *Journal of Energy in Southern Africa*, Vol. 23 no 4, November 2012.
5. Mao J., Zhang X., Li J., Wind power forecasting based on the BP neural network, Beifang University of Nationalities, Yinchuan, China;
6. Hernandez L., Artificial Neural Network for Short-Term Load Forecasting in Distribution Systems, *Energies* 2014, 7 1576–1598, ISSN1996-1073, marzec 2014, praca zbiorowa.
7. Perez-Llera C., Fernandez-Baizan M.C., Gonzalez del Valle V., Local Short-Term Prediction of Wind Speed: A Neural Network Analysis, Universidad Politecnica de Madrid, Spain.
8. Moghaddas-Tafreshi, S.M., Panahi D., One-hour-ahead forecasting of wind turbine power generation using artificial neural networks, University of technology, Teheran, Iran.

OPPORTUNITIES TO IMPROVE THE QUALTY OF FORECASTS OF WIND GENERATION USING AVAILABLE INFORMATION AS EXPANATORY VARIABLES

The article presents the results of analyzes refer to the capabilities of wind generation forecasting in selected case study, implemented by means of different methods of prediction, using a different range of measurement and forecasting data available Analyses focused on the evaluation of forecasts generated errors, input data of forecasting models selection and evaluation of the impact on the quality of prediction.

Keywords: forecasting, statistical methods, neural network