

Analiza jakości prognoz produkcji energii w elektrowniach wiatrowych opracowanych na podstawie danych meteo z modeli UM i COAMPS

Streszczenie. W artykule przedstawiono testy metody prognozowania produkcji energii z turbin wiatrowych z horyzontem 48 h wykorzystującej sztuczne sieci neuronowe. Wykonano prognozy na podstawie danych z modeli pogodowych UM i COAMPS. Przeanalizowano wyniki i sformułowano wnioski końcowe.

Abstract. The paper presents tests of method of 48 h ahead wind turbines electric energy production forecast by means of artificial neural networks. Forecasts using UM and COAMPS weather models were done. The results were analysed and final conclusions have been presented. (Quality Analysis of Wind Turbines Electrical Energy Production Forecasts Based on UM and COAMPS Meteo Data).

Słowa kluczowe: prognozowanie, turbiny wiatrowe, sztuczne sieci neuronowe, UM, COAMPS

Keywords: forecasting, wind turbines, artificial neural networks, UM, COAMPS

Przegląd literatury

Przy prognozowaniu produkcji mocy z OZE można się posłużyć danymi z wielu modeli pogodowych. Różnią się one głównie interwałami pomiędzy ich wyznaczaniem oraz określoną rozdzielczością siatki obliczeniowej. Wśród modeli można wyróżnić brytyjski model UM i amerykański model COAMPS stosowany przez ICM UW. Model UM charakteryzuje się siatką 4km i horyzontem prognozy 60/72 h, zaś dla modelu COAMPS krok siatki wynosi 13 km, a długość prognozy 84 h [1]. Kwalifikuje to modele pod względem skali odległościowej do modeli mezo γ wg skali Orłańskiego lub mezo β wg Skali Fujity [2]. Należą więc one do modeli średniej skali odległościowej. Obliczanie modelu UM odbywa się 4 razy na dobę, co 6 h każdego dnia poczynając od godziny 00:00 UTC. Dla modelu COAMPS zaś obliczenia są wykonywane o północy i 12:00 UTC. Oba z modeli wykazują specyficzne właściwości co do trafności prognoz pogody przez nie przedstawianych: model UM lepiej radzi sobie z prognozami opadów, przeprognozowuje prędkości wiatru (na wysokości referencyjnej 10 m), latem i jesienią wykazuje za wysoką temperaturę a zimą za małą (na 2 m wysokości). Model COAMPS z kolei wykazuje prawie zawsze zbyt wysoką temperaturę i znacznie заниżone ciśnienie zimą (na poziomie morza) [3].

Jako dane wejściowe do SSN przy stosowaniu ich do prognoz produkcji energii, można zastosować różne wielkości fizyczne. Mogą to być m.in. prognoza na podstawie krzywej mocy turbiny, ciśnienie, temperatura, wilgotność, kierunek wiatru, nasłonecznienie, opady, zachmurzenie, czy też prędkość wiatru [4,5,6]. Dla każdej z tych wielkości można określić korelację z prognozą produkcji mocy przez turbinę wiatrową, świadczącą o sile powiązania określonej wielkości z daną wyjściową. Dla celów określania danych przydatnych do badań można też uwzględnić zależność na moc chwilową turbiny wiatrowej [5]:

$$(1) \quad P = C_p \frac{\pi}{8} \rho D^2 v^3$$

gdzie: C_p – sprawność konwersji energii wiatru na energię mechaniczną, ρ – gęstość powietrza, w kg/m^3 , zależna od ciśnienia, temperatury i względnej wilgotności powietrza, D – średnica wirnika turbiny, v – prędkość wiatru, w m/s.

Z zależności tej wynika oczywisty wniosek dotyczący tego, jak silny jest wpływ prędkości wiatru na moc turbiny. Jest to więc przesłanka za tym, by wykorzystywać prognozę

prędkości wiatru do prognoz mocy, jako daną podstawową. Dlatego też wybrano prędkość wiatru jako daną wykorzystywaną w badaniach do prostego porównania prognoz mocy z turbin wiatrowych.

Bardzo istotnym zagadnieniem jest prawidłowy wybór miary oceny trafności prognoz. W literaturze można się spotkać z kilkudziesięcioma miarami oceny, zarówno prostymi, złożonymi, skalowanymi i znormalizowanymi [7,8,9,10]. Można się też posługiwać miarami pomocniczymi służącymi do oceny rozkładu wartości błędów [11,12]. Jednym z najczęściej występujących przypadłości miar jest występowanie wyrażen nieoznaczonych, asymetrii wartości błędów przy zmianie przeszacowania na niedoszacowanie prognoz czy też występowanie bardzo dużych wartości przy małej mocy rzeczywistej w danym momencie [8,9,10]. Dyskwalifikuje to miary takie jak m.in. popularne MAPE i jego niektóre modyfikacje. Uwzględniając te niedogodności oraz fakt, że turbiny wiatrowe przez większość czasu nie pracują z mocą znamionową jako zestaw miar oceny trafności prognoz wybrano zalecane wg. [7] miary: NMAE, NRMSE, NBIAS. Zostały one znormalizowane mocą średnią roczną z danej farmy wiatrowej, zaś jako miarę pomocniczą wybrano MAD. Ogólnie, błąd prosty prognoz można określić jako [7]:

$$(2) \quad e(t+k|t) = P(t+k) - \hat{P}(t+k|t)$$

gdzie: t – czas początkowy (moment rozpoczęcia prognozy), $k = 1,2 \dots k_{max}$ – krok czasowy prognozy, k_{max} – ostatni krok czasowy prognozy odpowiadający horyzontowi prognozy, $e(t+k|t)$ w MW – błąd prognoz odpowiadający czasowi $t+k$, $P(t+k)$ w MW – moc zmierzona przypadająca na moment $t+k$, $\hat{P}(t+k|t)$ w MW – moc zaprognozowana na moment $t+k$

Moc średnią roczną zastosowaną do normalizacji można zaś wyrazić jako:

$$(3) \quad \bar{P}(t+k) = \frac{1}{N} \sum_{t=1}^N P(t+k)$$

gdzie: N – liczba godzin prognoz w ciągu roku

Przy takim zapisie miary użyte w badaniach można wyrazić jako [7,8,11]:

$$(4) \quad NMAE [\%] = \frac{\frac{1}{N} \sum_{t=1}^N |e(t+k|t)|}{\frac{1}{N} \sum_{t=1}^N P(t+k)} * 100\%$$

$$(5) \quad NRMSE [\%] = \sqrt{\frac{\frac{1}{N} \sum_{t=1}^N e^2(t+k|t)}{(\frac{1}{N} \sum_{t=1}^N P(t+k))^2}} * 100\%$$

$$(6) \quad NBIAS [\%] = \frac{\frac{1}{N} \sum_{t=1}^N e(t+k|t)}{\frac{1}{N} \sum_{t=1}^N P(t+k)} * 100\%$$

$$(7) \quad MAD [MW] = \frac{1}{N} \sum_{t=1}^N |e(t+k|t) - \overline{e(t+k|t)}|$$

Zaobserwowane wstępnie różnice w jakościach prognoz z użyciem jednego modelu w określonym czasie, powodują że najbardziej sensowne wydaje się być kombinowanie danych z obu modeli prognostycznych, tak aby zwiększyć jakość wypadkowej prognozy produkcji mocy z OZE. Efekty takiego postępowania sprawdzono w poniższych badaniach przy zastosowaniu sztucznych sieci neuronowych typu MLP.

Opis badań

W ramach badań analizowano dokładność prognoz ex-post produkcji energii z farm wiatrowych przy użyciu sztucznych sieci neuronowych. Horyzont prognoz wynosił 48 h, ich kwant był godzinny, a daną wejściową dla sieci była historyczna prognozowana prędkość wiatru pochodząca z modeli prognoz pogody UM i COAMPS. Między tymi modelami dokonywano porównania wartości miar oceny trafności prognoz dla 2 wybranych farm wiatrowych. Wybrany zestaw miar stanowiły: NMAE, NRMSE, NBIAS oraz MAD, przy czym normalizacja miar odbywała się względem średniej rocznej mocy danej farmy wiatrowej. Pierwsza farma – nazwana Obiekt 1 charakteryzowała się położeniem w południowo zachodniej Polsce i mocą rzędu kilkudziesięciu MW. Druga farma – Obiekt 2, była zaś położona na północ od Obiektu 1 i charakteryzowała się prawie dwa razy większą mocą od Obiektu 1.

Proces badań

W badaniach zastosowano dla rozważanego horyzontu dwa warianty prognoz: prognozowanie modelem prostym, dokonującym predykcji na pełne 48 h (0-48) oraz prognozowanie modelem złożonym z modeli połówkowych, z których dla pierwszego zakresem prognoz były godziny 0-23 a dla drugiego 24-48. Oznacza to, że w praktyce obydwie podejścia generowały prognozy na 49 godzin naprzód. Tworzenie prognoz na 49 godzin (a nie jak w tytule 48) było związane ze zmianami czasu lokalnego (czas letni i zimowy). Natomiast modele meteorologiczne są wyznaczone według stałych punktów czasowych doby zgodnie z czasem UTC. Oznacza to, że aby móc codziennie wygenerować prognozę produkcji energii o tej samej porze czasu lokalnego (a takie było założenie badań) należy stosować horyzont prognozy o godzinę dłuższy.

Danymi wejściowymi wprowadzanymi do modelu była zaś historyczna prognozowana prędkość wiatru z UM, COAMPS, lub obu tych modeli jednocześnie. Przyjęto następujące oznaczenia modeli:

Model A - model prognostyczny z jednym wejściem SSN, prognozujący na pełne 48h;

Model B - model prognostyczny z jednym wejściem SSN składający się z dwóch modeli połówkowych dla godzin 0-23 i 24-48;

Model C - model prognostyczny z dwoma wejściami SSN z dwóch modeli meteorologicznych jednocześnie (UM i COAMPS), prognozujący na pełne 48h;

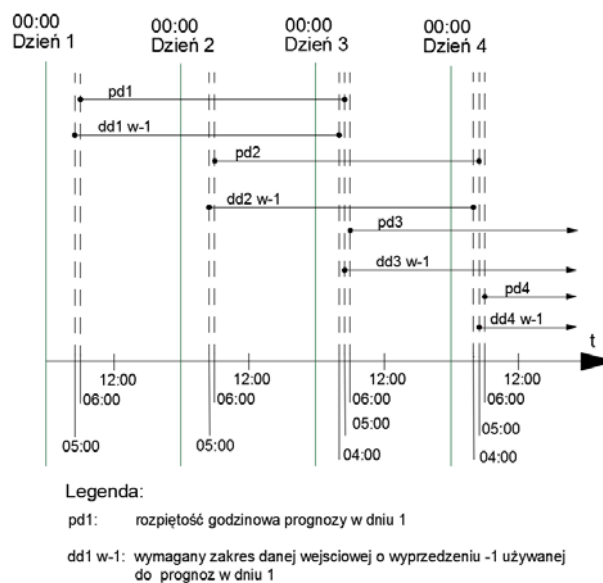
Model D - model prognostyczny z dwoma wejściami SSN z dwóch modeli meteorologicznych jednocześnie (UM i COAMPS), składający się z dwóch modeli połówkowych dla godzin 0-23 i 24-48.

Zarówno dla modeli prostych jak i modeli złożonych zastosowano postępowanie dwuetapowe. Najpierw przeprowadzano testy optymalnej architektury SSN dla wymienionej danej wejściowej a następnie przeprowadzano testy optymalnego wyprzedzenia tej danej. Wyniki z

najkorzystniejszą kombinacją wspomnianych miar oceny dokładności prognoz przechodziły do następnego etapu. Architektury rozważano przy tym w 3 wariantach:

- 1 warstwa ukryta z 7 neuronami,
- 2 warstwy ukryte z kolejno 10 i 7 neuronami,
- 3 warstwy ukryte z kolejno 13, 10 i 7 neuronami.

Rozważanymi wyprzedzeniami godzinowymi dla danych były zaś -24, -3, -2, -1, 0, 1, 2, 3, przy czym na etapie testów architektury wyprzedzenie miało wartość domyślną równą 0. Rysunek poglądowy przedstawiający zakresy prognoz i danej z wyprzedzeniem przedstawiono na rys. 1.



Rys. 1. Zakresy prognoz i przykładowe wyprzedzenie 1 danej wejściowej

Sieć neuronowa była uczona i testowana na danych od 2 stycznia 2013 do 29 lutego 2015, a okresy uczące i testowe sieci dobierano tak, aby stosunek czasu trwania okresów uczących do sumy trwania okresów uczących i testowych wynosił 80%. Dla Obiektu 1 liczba godzin uczących wyniosła 24132, a godzin testowych 5424. Dla Obiektu 2 liczba godzin wyniosła odpowiednio 23988 i 5424. Dla obu obiektów w.w stosunek wyniósł więc ok. 82%. Walidacja działania modelu była przeprowadzana na okresie od 1 marca 2015 do 29 lutego 2016. Ze względu na braki niektórych danych, realna walidacja została podzielona na 3 okresy, które później były składane w całość.

Okresy te oraz ich zakresy godzinowe były następujące:

- 01-03-2015 do 05-06-2015 00:00 –23:00
- 09-06-2015 do 29-07-2015 00:00 –23:00
- 02-08-2015 do 02-29-2016 00:00 –23:00

Łącznie walidacja była przeprowadzana na 17532 godzinach, przez co stosunki sumy liczby godzin uczących i testowych do liczby godzin walidacji wyniosły 1,685 dla Obiektu 1 oraz 1,677 dla Obiektu 2. Wyniki badań, będące wskaźnikami jakości prognoz, zostały podane dla całego okresu walidacyjnego i zestawiono je w tabelach 1-2.

Ze względu na obszerność wyników, wyniki testów wyprzedzeń zostały zestawione w tabelach, zaś testów architektury zostały opisane słownie. Najlepsze wyniki badań zestawiono na rysunkach 2-5, przy czym tabela 1 dotyczyła badań SSN z jednym wejściem, zaś tabela 2 badań sieci z dwoma wejściami. W tabelach najlepsze wyprzedzenia dla wariantu badań zaznaczono kolorem szarym.

Wyniki badań

Architekturą, której wybór okazywał się optymalny najczęściej była architektura jednowarstwowa. Okazała się ona optymalna w 6 z 12 przypadków badań. Dla porównania architektura dwuwarstwowa okazała się optymalna w 5 przypadkach, a architektura trzywarstwowa tylko w jednym. W przypadku badań modeli z 1 wejściem SSN architektura jednowarstwowa była optymalna przy stosowaniu modeli COAMPS, zarówno prostych jak i złożonych, zaś dla modeli UM w 3 z 4 przypadków, lepsza okazała się architektura z 2 warstwami ukrytymi. Dla modeli

z 2 wejściami SSN, architektura jednowarstwowa okazała się lepsza dla Obiektu 1, zaś dla Obiektu 2, lepszą była architektura z dwiema warstwami ukrytymi. Zgodnie z przewidywaniami, przy małej liczbie wejść architektura z trzema warstwami ukrytymi nie sprawdzała się, zaś architektura jednowarstwowa, choć w teorii powinna być wystarczająca, nie zawsze okazywała się optymalna. Świadczy to o konieczności przeprowadzenia testu architektury przy badaniu nowego przypadku.

Tab.1 Testy wyprzedzeń prognozowanej prędkości wiatru – 1 wejście SSN, Obiekt 1 i 2

Przypadek	Model A, UM				Model A, COAMPS				Model B, UM				Model B, COAMPS				
	NMAE [%]	NRMSE [%]	NBIAS [%]	MAD [MW]	NMAE [%]	NRMSE [%]	NBIAS [%]	MAD [MW]	NMAE [%]	NRMSE [%]	NBIAS [%]	MAD [MW]	NMAE [%]	NRMSE [%]	NBIAS [%]	MAD [MW]	
Wyprzedzenie	Wartości miar dla Obiektu 1 przy danym wyprzedzeniu																
	-24	84,7	109,8	8,2	6,63	81,3	106	8,0	6,44	85,6	109,8	4,4	6,64	81,6	106	3,9	6,31
	-3	84,7	109,8	8,2	6,63	65,9	88,2	-3,9	5,00	62,3	82,1	-11,7	4,53	65,6	88,2	-0,3	5,02
	-2	60,7	79,1	-13,6	4,36	65,1	87,0	-4,2	4,93	57,9	78,7	-8,6	4,73	65,4	87,5	-3,4	4,94
	-1	58,9	76,7	-13,7	4,23	63,3	86,3	1,6	4,87	57,8	76,3	-13,0	4,16	64,0	87,1	1,9	4,92
	0	57,5	75,8	-6,9	4,28	63,7	86,7	-3,3	4,84	56,9	76,3	-9,5	4,18	63,7	86,6	0,4	4,89
	1	61,0	79,0	-14,0	4,38	64,5	87,6	-4,9	4,87	58,9	79,2	-10,5	4,31	64,7	87,6	-4,8	4,89
	2	61,5	82,0	-8,1	4,55	65,2	88,7	-3,5	4,94	63,1	82,6	-12,5	4,58	65,4	89,1	-1,8	4,99
3	64,1	85,4	-6,9	4,78	66,6	90,2	-2,7	5,07	65,8	86,1	-11,4	4,81	66,4	90,1	-0,7	5,08	
Wyprzedzenie	Wartości miar dla Obiektu 2 przy danym wyprzedzeniu																
	-24	72,6	92,1	22,9	11,95	71,5	90,8	21,7	11,78	73,5	93,6	24,5	12,12	71,8	92,6	27,7	11,81
	-3	48,1	63,4	12,3	7,92	58,6	78,6	28,9	9,60	48,2	63,8	13,0	7,94	57,7	77,2	26,4	9,47
	-2	45,4	60,7	12,2	7,49	56,8	76,2	27,7	9,30	44,8	60,6	14,9	7,39	56,2	75,0	24,1	9,25
	-1	43,7	58,3	8,8	7,20	54,8	74,5	28,8	8,94	43,5	58,4	12,0	7,17	55,6	75,3	27,7	9,12
	0	42,0	57,8	17,6	6,89	53,6	72,4	26,3	8,76	43,6	60,3	16,8	7,20	53,9	73,4	27,7	8,80
	1	44,7	60,8	16,7	7,36	53,2	72,4	26,9	8,68	46,3	62,8	16,6	7,64	53,4	73,0	28,3	8,67
	2	49,4	64,6	9,4	8,12	55,3	75,2	29,6	9,00	49,4	65,8	15,9	8,15	55,0	75,0	29,4	8,97
3	54,3	73,6	24,1	8,97	56,0	75,6	27,7	9,13	51,7	67,6	13,3	8,51	55,6	73,8	21,6	9,13	

Tab.2 Testy wyprzedzeń prognozowanej prędkości wiatru – 2 wejścia SSN

Przypadek	Model C Obiekt 1				Model D, Obiekt 1				Model C Obiekt 2				Model D, Obiekt 2				
	NMAE [%]	NRMSE [%]	NBIAS [%]	MAD [MW]	NMAE [%]	NRMSE [%]	NBIAS [%]	MAD [MW]	NMAE [%]	NRMSE [%]	NBIAS [%]	MAD [MW]	NMAE [%]	NRMSE [%]	NBIAS [%]	MAD [MW]	
Wyprzedzenie	Wartości miar przy danym wyprzedzeniu																
	-24	53,7	72,8	-7,2	4,00	57,0	75,2	-12,8	4,15	46,0	65,4	25,4	7,62	42,5	59,1	16,8	7,02
	-3	51,5	69,5	-14,5	3,71	50,9	69,1	-12,7	3,71	41,6	57,6	20,4	6,83	42,6	59,7	22,4	6,95
	-2	51,0	69,4	-15,4	3,67	51,3	69,4	-15,0	3,72	42,0	56,5	13,7	6,98	42,6	59,5	20,0	6,96
	-1	51,6	69,9	-17,4	3,73	50,2	68,4	-13,8	3,65	42,6	56,4	10,6	7,05	43,2	60,6	25,0	7,02
	0	50,1	68,5	-14,6	3,64	49,8	68,4	-13,0	3,66	41,1	55,7	14,9	6,82	41,2	55,7	13,3	6,81
	1	51,6	70,5	-17,9	3,73	50,3	69,0	-14,6	3,65	41,4	56,3	16,7	6,84	42,6	58,8	21,6	6,94
	2	51,1	70,2	-15,6	3,74	51,1	70,1	-15,1	3,73	40,3	54,8	14,3	6,64	41,7	58,5	18,5	6,81
3	50,2	69,0	-8,8	3,73	52,0	71,4	-13,7	3,84	42,5	56,6	13,0	7,03	43,1	59,9	19,5	7,12	

Dla testów architektury SSN z jednym wejściem, najlepsze wyniki wykazywały modele proste z wejściami z modelu UM. Dla Obiektu 1 NMAE wyniosło 57,5% ; NRMSE: 75,8%; NBIAS: -6,9 MW; MAD: 4,276 MW. Architekturą optymalną okazała się być w tym przypadku trójwarstwowa. Dla Obiektu 2 zaś, optymalne NMAE wyniosło 42% ; NRMSE: 57,8%; NBIAS: 17,6 MW; MAD: 6,893 MW. Architektura optymalna była dwuwarstwowa. Dla Obiektu 1, w porównaniu do wariantu optymalnego, najlepsze modele COAMPS wykazywały ok. 6% większe NMAE, ok. 11% większe NRMSE, MAD wyższe o ok. 0,6 MW i kilkukrotnie niższy, a w jednym przypadku prawie zerowy NBIAS. Dla Obiektu 2, modele COAMPS o najlepszej architekturze ze swoich wariantów, w stosunku do modelu optymalnego testów architektury Obiektu, wykazywała ok 12% większy NMAE, ok. 14-15% większe NRMSE, ok. 9-10% większy NBIAS i ok. 2 MW większy MAD.

W przypadku modeli kombinowanych, najlepsze okazały się modele złożone, które jednak od modeli prostych nie różniły się aż tak bardzo. Między ich wartościami NMAE i NRMSE, różnica wyniosła od 0% do 0,3% (tylko raz). Największą różnicę można było zaobserwować na wartościach NBIAS między tymi modelami. Dla Obiektu 1 optymalne NMAE wyniosło 49,8%, NRMSE: 68,4%, NBIAS: -13,4 MW, MAD: 3,66 MW, a architektura była jednowarstwowa. Dla Obiektu 2 zaś, optymalne NMAE wyniosło 41,2%, NRMSE: 55,7%, NBIAS: 13,3 MW, MAD: 6,81 MW, a architektura była dwuwarstwowa.

Z porównania optymalnych wyników samych testów architektury było widoczne, że modele kombinowane pozwalają na osiągnięcie mniejszych niedokładności predykcji. Dla Obiektu 1 model kombinowany umożliwił zmniejszenie NMAE i NRMSE o ok. 7%, a MAD o ok. 0,6 MW. Stało się to jednak kosztem zwiększenia NBIAS o


6,5%. Dla Obiektu 2 model kombinowany umożliwił zmniejszenie NMAE o 0,8%, NRMSE o ok. 2%, MAD o ok. 0,08 MW, a NBIAS o 4,3%.

Obserwacje i wnioski

Jak można zaobserwować na rysunkach 2 i 3, wśród prawie wszystkich wyników dla obu zestawionych obiektów, Modele A charakteryzowały się niższymi wartościami błędów w porównaniu do modeli składanych. Modele A UM wykazały przy tym wartości NRMSE i NMAE niższe, niż te odpowiadające ich modelom COAMPS. Porównując wartości pomiędzy dwoma obiektami, można też było zauważyć, iż dla Obiektu 2 uzyskane wartości błędów były niższe niż dla Obiektu 1. Widoczne były również większe różnice wartości NMAE i NRMSE między modelami prostymi a składanymi UM, w porównaniu do modeli bazujących na COAMPS. Ponieważ moc średnia roczna Obiektu 2 była ok. dwa razy większa niż moc Obiektu 1, wartości błędów wyrażone w MW były przy tym dla Obiektu 2 zauważalnie większe.


Na rys.5 można zauważyć, że dla każdego modelu Obiektu 1 tendencja prognoz do przeszacowywania lub niedoszacowywania (NBIAS) była niższa niż dla modeli Obiektu 2. Porównując zmiany zachodzące na wykresie 2, 3 i 5 można wskazać, że różnicom w wartościach NMAE i NRMSE między modelami A oraz modelami składanymi, odpowiadała przeciwna i proporcjonalna różnica między ich wartościami NBIAS. Inaczej mówiąc zmniejszenie wartości błędów NMAE i NRMSE, wynikające z zastosowania Modelu A było kompensowane wzrostem występującej wcześniej tendencji rozwojowej. Ponadto, można było zauważyć, iż przy ciągłym zmniejszaniu NMAE i NRMSE, NBIAS wykazywało przyrost odpowiadający kilkakrotności wielkości zmian wartości błędów NMAE. Dlatego też, zejście wartości NMAE i NRMSE w modelach Obiektu 2 do dość niskiego poziomu pociągnęło za sobą znaczny wzrost wartości NBIAS tych samych modeli. W skrajnym przypadku, oznaczało to, że każdy kwant był potencjalnie obciążony błędem sięgającym nawet kilkunastu procent mocy średniej farmy wiatrowej.

Obiekt 1




Rys.2 Błędy NMAE i NRMSE dla Obiektu 1

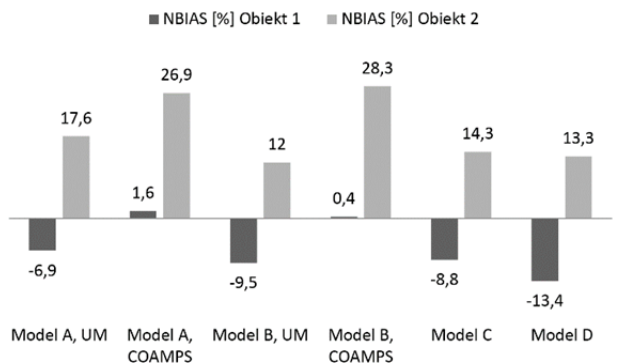
Obiekt 2



Rys.3 Błędy NMAE i NRMSE dla Obiektu 2



Rys.4 Błąd MAD dla Obiektu 1 i Obiektu 2



Rys.5 Błąd NBIAS dla Obiektu 1 i Obiektu 2

Obserwując rys. 4 można zauważyć, że modele prognostyczne produkcji mocy bazujące na modelu prognoz pogody UM, wykazywały większą średnią koncentrację wartości błędów prostych wokół wartości średniej błędu niż modele bazujące na COAMPS. Łącząc zaś informacje przedstawione na rysunkach 4 i 5, można się przekonać, że modele korzystające z COAMPS wykazywały zauważalnie większe odsunięcie zakresu wahań tendencji prognostycznej od 0. Działo się tak nawet pomimo niższych wartości NBIAS dla Obiektu 1 w tych modelach. Oznacza to, że modele prognoz produkcji mocy bazujące na COAMPS charakteryzują się nie tylko silnymi błędami bezwzględными i średniokwadratowymi, ale też dużo większym niedoszacowaniem prognoz. Modele bazujące na UM okazały się więc przy wykorzystywaniu prognozowanej prędkości wiatru jako jedynego wejścia SSN, lepsze we wszystkich aspektach.

Z porównania rysunków 2,3 i 4 wynika, że zastosowanie modeli prognozowania produkcji mocy z dwoma wejściami sztucznej sieci neuronowej spowodowało wyraźne obniżenie wartości NMAE i NRMSE w obu analizowanych wariantach dla obu obiektów. W stosunku do modeli prostych wykorzystujących jedynie jedno wejście z prognozowaną prędkością wiatru z modelu COAMPS, zanotowano poprawę wartości NMAE rzędu 13%, zaś w stosunku do modeli korzystających z jednego wejścia z modelu UM poprawa wyniosła 7,3% (Obiekt 1) i 1,7% (Obiekt 2). Wartości NRMSE dla modeli prostych poprawiły się z kolei o 6,8% (UM, Obiekt1), 3% (UM, Obiekt 2) i ponad 17% dla modeli COAMPS obu obiektów. W przypadku porównywania modeli złożonych, po zastosowaniu modelu z dwoma wejściami SSN wartości NMAE poprawiły się o 7,1% (UM, Obiekt 1), 2,3% (UM, Obiekt 2), 13,9% (COAMPS, Obiekt 1), 12,2% (COAMPS, Obiekt 2). Wartość NRMSE poprawiła się zaś o 7,9% (UM, Obiekt 1), 2,7% (UM, Obiekt 2), 18,2% (COAMPS, Obiekt 1), 17,3% (COAMPS, Obiekt 2). Największa poprawa została więc zaobserwowana w modelach COAMPS i

wyniosła ona kilkanaście procent, zaś dla modeli obu obiektów korzystających z UM poprawa wyniosła od 1,7% do 7,1%, co zgadzało się z przewidywaniami teoretycznymi. Jednocześnie z porównania modeli na rys. 2,3,4 wynika, że dla Obiektu 1, zarówno w przypadku modelu prostego oraz złożonego z 2 wejściami zanotowano zwiększenie o kilka % wartości NBIAS w stosunku do wartości najgorszych z modeli z 1 wejściem. W przypadku Obiektu 2 zanotowano natomiast około dwukrotne zmniejszenie wartości NBIAS w stosunku do największych wartości występujących w modelach z 1 wejściem. Porównując wartości na rys. 4 można natomiast zauważyć, że po zastosowaniu modeli z 2 wejściami SSN wartości MAD dla wszystkich modeli zauważalnie zmalały, co oznaczało, że wartość błędu średniego w mniejszym stopniu wynikała z kompensacji błędów niedoszacowania i przeszacowania, niż w przypadku modeli z 1 wejściem.

Wszystkie wyżej wymienione czynniki przemawiają na korzyść stosowania modeli prognostycznych wykorzystujących zarówno dane z modelu UM jak i COAMPS, gdyż charakteryzują się one mniejszymi błędami NMAE i NRMSE, zauważalnie lepszymi lub nieznacznie gorszymi wartościami NBIAS oraz większym zbliżeniem wartości błędów do średniej, w porównaniu do modeli korzystających tylko z jednego wejścia UM / COAMPS. Porównując dla modeli dwuwejściowych trafność prognoz między modelami prostymi i złożonymi i odnosząc to do modeli jednowejściowych okazuje się, że nawet przy 2 wejściach SSN model prosty może, choć nie musi dawać lepsze wyniki niż model złożony, co świadczy o potrzebie przeprowadzania testów prognoz dla obu typów modeli.

Autorzy dziękują firmie Globema Sp. z o.o. za udostępnienie danych zebranych w ramach realizacji projektu 4RES.

Autorzy: dr hab. inż. Dariusz Baczyński, Politechnika Warszawska, Instytut Elektroenergetyki, ul.Koszykowa 75,00-662 Warszawa, E-mail: dariusz.baczyński@ee.pw.edu.pl; mgr inż. Marcin Kopyt, Instytut Elektroenergetyki, ul.Koszykowa 75,00-662 Warszawa, E-mail: marcin.kopyt@ee.pw.edu.pl

LITERATURA

- [1] Interdyscyplinarne centrum modelowania matematycznego i komputerowego. Numeryczna prognoza pogody. [Online] <http://www.meteo.pl>
- [2] Markowski P., Richardson Y. Mesoscale Meteorology in Midlatitudes : Wiley-Blackwell, 2010.
- [3] Melonek Małgorzata. Porównanie wyników weryfikacji modeli numerycznych prognoz pogody działających operacyjnie w ICM. Infrastruktura i ekologia terenów wiejskich. 2011, 6, strony 31-42.
- [4] Baczyński D. , Piotrowski P. Prognozowanie dobowej produkcji energii elektrycznej przez turbinę wiatrową z horyzontem 1 doby. *Przegląd elektrotechniczny*. 2014, 90, strony 113-117.
- [5] Piotrowski P. Analiza statystyczna oraz prognozy dobowej produkcji energii przez farmę wiatrową z z horyzontem 1 doby. *Elektro.info*. 2012, 4.
- [6] Piotrowski P. Analiza statystyczna danych mających wpływ na produkcję energii elektrycznej przez farmę wiatrową oraz przykładowe prognozy krótkoterminowe. *Przegląd Elektrotechniczny*. 2012, 3a, strony 161-164.
- [7] Madsen H. Kariniotakis G, Nielsen H.Aa., Nielsen T.S., Pinson P. Standardizing the Performance Evaluation of Short-Term Wind Power Prediction Models. *Wind Engineering*. 2005, Tom 29, 6. http://pierrepinson.com/docs/madsen05_protocol.pdf, aktualne na dzień 5.05.2016.
- [8] Shaker H., Zareipour H., Wood D., On error measures in wind forecasting evaluations. : 26th IEEE Canadian Conference Of Electrical And Computer Engineering (CCECE), 2013.
- [9] Hyndman Rob J., Koehler Anne B., Another Look at Measures of Forecast Accuracy. Maj 2005.
- [10] Hyndman R. J., Errors on percentage errors. [Online] 16 04 2014. <http://robjhyndman.com/hyndsight/smapel/>, aktualne na dzień 13.05.2016.
- [11] Wallström Peter. Evaluation of forecasting techniques and forecast errors with focus on intermittent demand. Luleå : Luleå University of Technology, May 2009.
- [12] Panichkitkosolkul W., Confidence Intervals for the Coefficient of Variation in a Normal Distribution with a Known Population Mean. *Journal of Probability and Statistics*. 2013, Tom 2013, Article ID 324940. <http://dx.doi.org/10.1155/2013/324940>