

Prognozowanie dobowej produkcji energii elektrycznej przez turbinę wiatrową z horyzontem 1 doby

Streszczenie. W tekście przedstawiono analizę statystyczną danych mogących mieć znaczenie w procesie prognozowania dobowej produkcji energii przez turbinę wiatrową. Wykonano przykładowe prognozy oraz sformułowano wnioski końcowe.

Abstract. The paper presents statistical analysis of data potentially useful in wind electric energy forecasting process for wind turbine. Examples of predictions have been executed and the final conclusions have been presented. (A one day ahead forecasting of twenty-four-hour electric energy production for wind turbine)

Słowa kluczowe: turbina wiatrowa, analiza statystyczna danych, prognozowanie krótkoterminowe, sztuczne sieci neuronowe, optymalizacja rojem cząstek.

Keywords: wind turbine, statistical analysis of data, short term forecasting, artificial neural network, particle swarm optimization.

doi:10.12915/pe.2014.09.31

Wstęp

Rozwój energetyki odnawialnej w Polsce sprawia, że analizy zmienności produkcji energii elektrycznej przez farmy wiatrowe, a w szczególności krótkoterminowe prognozy godzinowe produkcji, są istotnym zagadnieniem pracy systemu elektroenergetycznego [23,24,25]. Tematyce tej poświęconych zostało wiele publikacji [2,7,11,12,13,14,15,16,17,18,23,24,25].

Dynamiczny w ostatnich latach rozwój energetyki wiatrowej w Polsce powoduje, że rola takich prognoz cały czas rośnie. Godzinowe prognozy są istotne w procesie optymalizacji rozdziału obciążeń i bilansowania mocy w systemie, natomiast maksymalny błąd prognozy jest wskaźnikiem niezbędnego poziomu rezerwy mocy wymaganej do bilansowania systemu elektroenergetycznego [13, 23, 24].

Prognozy godzinowe są istotne zarówno dla operatorów systemów przesyłowych i dystrybucyjnych, ale także dla operatorów odnawialnych źródeł energii. Właściciele OZE dzięki tego rodzaju prognozom mogą lepiej planować prace eksploatacyjne oraz uczestniczyć w rynkach energii elektrycznej. Jednak, jak wynika z praktyki działania operatorów farm wiatrowych, niektórzy z nich podejmują ostateczne decyzje operacyjne o odstawieniu do remontu lub przeglądu pojedynczych turbin na podstawie prognozy ich dziennej produkcji. W artykule skoncentrowano się na nietypowej prognozie całkowitej dobowej wielkości produkcji energii elektrycznej generowanej przez pojedynczą turbinę (najbardziej przydatna przy wykorzystaniu zasobników energii). Sztuczne sieci neuronowe jako nieliniowy estymator wg licznych źródeł wydają się obiecującą metodą prognoz krótkoterminowych zapotrzebowania na energię [1,6,8,9,10,17,20,21,22], jak również produkcji energii przez farmy wiatrowe [14,15,28,31], i to narzędzie zostało wykorzystane w wykonanych prognozach. Wspomaganie sieci neuronowej algorytmem optymalizacji rojem cząstek (PSO) jest również znane z literatury [3,4,5,26,29].


Analiza statystyczna danych oraz dobór właściwych danych do metod prognostycznych

Analizie poddane zostały dane z okresu od 27.01.2009 do 13.11.2010 z pojedynczej turbiny wiatrowej z farmy zainstalowanej w południowej części Polski (tab.1). Nominalna moc produkcji energii elektrycznej przez całą turbinę wiatrową wynosiła 200 kW. Liczebność analizowanego szeregu czasowych wynosiła 656. Brakujących danych ani anormalnych wartości maksymalnych nie stwierdzono w szeregu czasowym. Wyraźnego trendu ani okresowości nie wykryto. Test


Shapiro-Wilka oraz Kołmogorowa-Smirnowa wykazały, że szereg czasowy nie ma rozkładu normalnego.

Tabela 1. Dane statystyczne o produkcji energii w okresach 1-dobowych ze wszystkich dni w okresie 27.01.2009-14.11.2010

Miara statystyczna	Produkcja energii elektrycznej [kWh]
Wartość maksymalna	2313,8
Wartość minimalna	0,0
Wartość średnia	276,6
Odchylenie standardowe	398,0
Mediana	111,1
Skośność	2,3
Kurtoza	5,7



Rys.1. Przebieg dobowej produkcji energii elektrycznej przez turbinę wiatrową w roku 2009



Rys.2. Przebieg dobowej produkcji energii elektrycznej przez turbinę wiatrową w roku 2010

Stosunek średniej produkcji dobowej turbiny wiatrowej do maksymalnej dobowej produkcji teoretycznej (200 kWh*24) był niski i wynosił zaledwie 5,2%. Średnia prędkość wiatru w analizowanym okresie czasu, mierzona dla każdej godziny doby wynosiła tylko 2,34 m/s. Produkcja energii była zerowa dla 5% wszystkich analizowanych dni. Nieco mniejszy poziom produkcji energii miał miejsce w

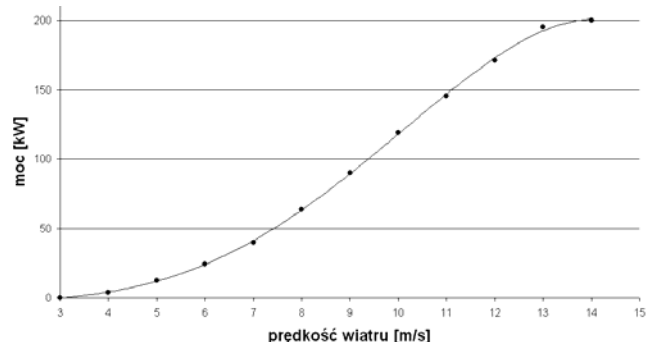
miesiącach letnich Współczynnik zmienności V_Z dla danych o produkcji energii elektrycznej przez turbinę wiatrową wyniósł aż 144%.

Przebiegi produkcji energii elektrycznej przez farmę wiatrową w 2 kolejnych latach, wykazują duży stopień chaotyczności produkcji energii w okresie kolejnych dób oraz małą powtarzalność (rok do roku, miesiąc do miesiąca). Zwraca ponadto uwagę bardzo duża rozpiętość wielkości produkowanej energii elektrycznej w poszczególnych dniach. Przebiegi dobowej produkcji energii elektrycznej przez turbinę wiatrową w roku 2009 oraz 2010 przedstawiają rysunki 1 oraz 2.

Na podstawie danych producenta [30] (moc turbiny dla różnych wartości prędkości wiatru podawana z krokiem 1) dokonano estymacji zmienności mocy w zależności od prędkości wiatru do postaci funkcji, dzięki której oszacować można moc pojedynczej turbiny wiatrowej dla innych wartości prędkości wiatru niż liczby całkowite z zakresu od 3 do 14 podane przez producenta. Wzór pozwalający obliczyć moc przyjął postać wielomianu stopnia 4

$$(1) \quad P = -0,0299 * (v - 2)^4 + 0,516 * (v - 2)^3 - 0,7491 * (v - 2)^2 + 3,5095 * (v - 2) - 3,4576$$

gdzie: P – moc turbiny wiatrowej [kW], v – prędkość wiatru [m/s].



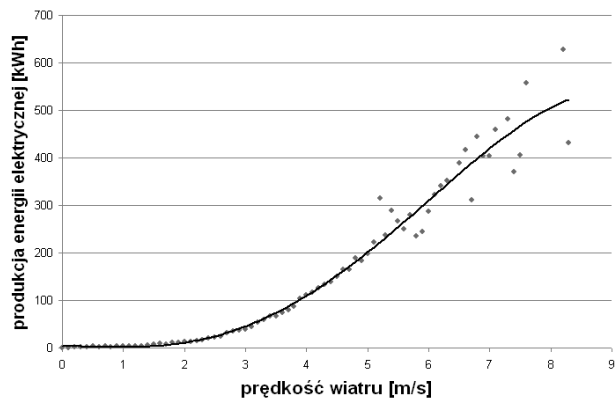
Rys.3. Wykres punktowy zmienności mocy w zależności od prędkości wiatru dla turbiny VESTAS V25 200-30 25.0 oraz liniowy wielomianu ze wzoru (1)

Wykorzystując wzór (1) i mnożąc uzyskane wartości przez 24 otrzymano oszacowania wartości dobowej produkcji energii dla całego zakresu dostępnych danych. Ponadto opracowano wzór na godzinową wartość produkcji energii elektrycznej przez całą farmę wiatrową (4 turbiny) w zależności od prędkości wiatru - na podstawie dostępnych danych obliczono średnią produkcję energii dla dostępnych wartości prędkości wiatru (z krokiem 0,1), a następnie wykonano estymację uzyskanej krzywej do wzoru (rys.4)

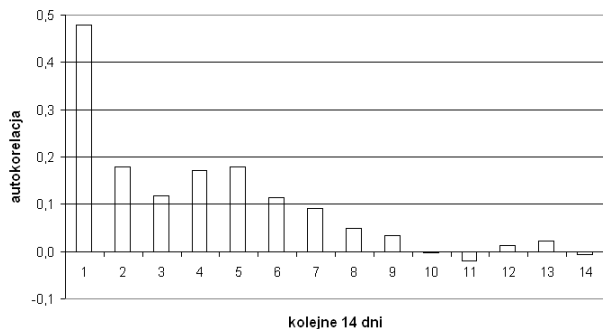
$$(2) \quad E = -0,304 * v^4 + 3,853 * v^3 - 3,116 * v^2 - 3,333 * v + 4,109$$

gdzie: E – godzinowa wartość produkcji energii elektrycznej przez farmę wiatrową [kWh].

Wykorzystując wzór (2) i dzieląc uzyskane wartości przez 4 i mnożąc przez 24 otrzymano oszacowania wartości dobowej produkcji energii dla całego zakresu dostępnych danych. Analiza autokorelacji szeregu czasowego produkcji energii elektrycznej przez farmę wiatrową obejmowała 30 dni wstecz (rys.5). W praktyce tylko produkcja energii z ostatniego dnia przed dniem prognozy miała stosunkowo wysoki współczynnik autokorelacji wynoszący 0,479.




Rys.4. Wykres punktowy zmienności energii w zależności od prędkości wiatru dla farmy wiatrowej oraz liniowy wielomianu ze wzoru (2)



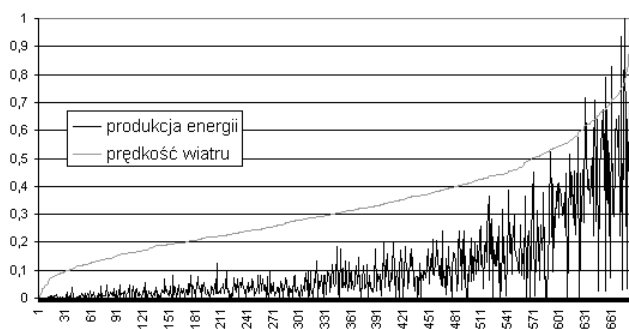
Rys.5. Autokorelacja szeregu czasowego produkcji energii elektrycznej przez farmę wiatrową w okresie do 14 dni wstecz

Wyniki analizy korelacji wielkości dobowej produkcji energii z czynnikami mającymi potencjalnie wpływ na poziom produkcji zawarto w tabeli 2. Charakterystyczna była silna zależność pomiędzy dobową produkcją energii a prędkością wiatru oraz szacowaną produkcją energii obliczoną ze wzorów (1) oraz (2). Rysunek 6 przedstawia korelację produkcji energii z ciśnieniem atmosferycznym, a rysunek 7 z prędkością wiatru – dane zostały znormalizowane do zakresu $<0,1>$ oraz uporządkowane rosnąco wg czynnika wpływającego na produkcję energii elektrycznej. Weryfikacja istotności korelacji z tabeli 2 oraz korelacji wzajemnych pomiędzy tymi danymi, wykazała, że w większości przypadkach ich istotność z $p < 0,05$ (5% poziom istotności). Korelacje statystycznie nieistotne zostały w tabeli przekreślone.



Rys.6. Korelacja pomiędzy produkcją energii elektrycznej oraz ciśnieniem atmosferycznym.

Współczynnik korelacji cząstkowej pomiędzy produkcją energii elektrycznej a ciśnieniem atmosferycznym z wyłączeniem wpływu prędkości wiatru wyniósł -0,159



Rys.7. Korelacja pomiędzy produkcją energii elektrycznej oraz prędkością wiatru

Tabela 2. Korelacja wybranych czynników z dobową produkcją energii elektrycznej

Czynnik	Współczynnik korelacji
Temperatura – prognoza [stopnie Celcjusza]	-0,138
Ciśnienie atmosferyczne – prognoza [hPa]	-0,361
Zachmurzenie – prognoza [skala 0-8, brak zachmurz - 0]	0,063
Nasłonecznienie – prognoza [Wh/m2]	-0,189
Prędkość wiatru – prognoza [m/s]	0,809
Prędkość wiatru [m/s] w dniu d-1	0,380
Prędkość wiatru [m/s] w dniu d-2	0,127
Prędkość wiatru [m/s] w dniu d-3	0,057
Kierunek wiatru - prognoza [azymut]	0,158
Opady – prognoza [mm/h]	0,048
Dobowa produkcja energii obliczona z funkcji zależności mocy od prędkości wiatru (estymacja na podstawie danych producenta)	0,803
Dobowa produkcja energii obliczona z funkcji zależności mocy od prędkości wiatru (estymacja na podstawie rzeczywistych pomiarów)	0,843
Produkcja energii w dniu d-1	0,477
Produkcja energii w dniu d-2	0,179
Produkcja energii w dniu d-3	0,117
Średnia miesięczna wartość produkcji energii obliczona na podstawie danych historycznych	0,368

Dobór zmiennych do modelu ekonometrycznego oraz modeli sieci neuronowych wykonano wspomagając się metodą analizy grafów (metoda Bartosiewicza). Wyznaczono macierz \mathbf{R} współczynników korelacji liniowej pomiędzy potencjalnymi zmiennymi objaśniającymi. Dla danego poziomu istotności $\alpha = 0,05$ oraz 13 stopni swobody obliczono wartość t_{α} rozkładu t -Studenta, która wyniosła 2,15. Następnie wyznaczono wartość krytyczną współczynnika korelacji r^* , która wyniosła 0,513. W macierzy \mathbf{R} wyzerowano wszystkie współczynniki korelacji dla których zachodzi nierówność $|r_{ij}| < r^*$. Na podstawie macierzy \mathbf{R} zbudowano grafy powiązań między kandydatami na zmienne objaśniające. Wybraną zmienną objaśniającą występującą w grafach izolowanych było ciśnienie atmosferyczne (prognoza na dzień d). Pozostałe wybrane zmienne stanowiły zmienne o maksymalnej liczbie łuków wybrane z każdego grafu spójnego. W wyniku przeprowadzonej analizy wybrano ostatecznie jako zmienne objaśniające do modeli prognostycznych: (1) ciśnienie atmosferyczne (prognoza na dzień d), (2) prędkość wiatru (prognoza na dzień d), (3) prędkość wiatru w dniu d-1, (4) produkcja energii w dniu d-1, (5) średnia miesięczna wartość produkcji energii obliczona na podstawie danych historycznych, (6) dobową wielkość produkcji energii szacowaną z wykorzystaniem wzoru (2). Wartości współczynników zmienności V_X poszczególnych zmiennych objaśniających wyniosły: 46,51% dla średniej miesięcznej wartości produkcji energii, 0,79% dla ciśnienia

atmosferycznego, 40,37% dla prędkości wiatru oraz 301,41% dla szacunkowej mocy farmy obliczonej z funkcji zależności mocy od prędkości wiatru. Wszystkie analizowane zmienne objaśniające miały więc wystarczające zróżnicowanie oprócz ciśnienia atmosferycznego. Zmienną jednak zachowano z uwagi na stosunkowo wysoki współczynnik korelacji ze zmienną objaśnianą.

Prognozy dobowej produkcji energii wybranymi metodami.

Dane służące do estymacji modeli pochodziły z okresu od 27.01.2009 do 31.08.2010, natomiast dane testowe (weryfikacja jakości testowanych modeli) pochodziły z okresu od 1.09.2010 do 13.11.2010. Tabela 3 przedstawia wybrane wyniki prognoz z zakresu estymacji (dane treningowe) oraz zakresu weryfikacji (dane testowe). W nawiasach w kolumnie „metoda prognostyczna” podano wykorzystane zmienne objaśniające w danej metodzie. Jako podstawową miarę błędu przyjęto znormalizowany pierwiastek średniokwadratowego błędu – nRMSE z uwagi na występujące w szeregu czasowym wartości rzeczywiste równe zero.

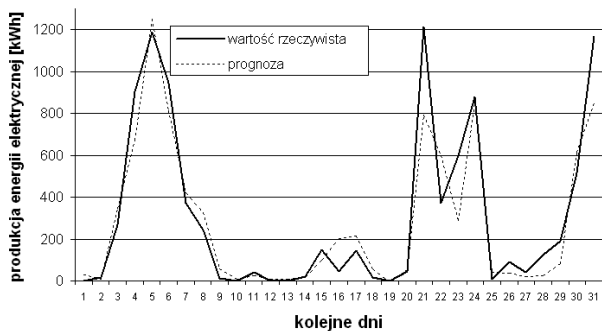
$$(3) \quad nRMSE = \frac{\sqrt{\sum_{t=1}^T (y_t^* - y_t)^2}}{E_n \cdot \sqrt{T}}$$

gdzie: y_t^* - prognoza produkcji energii, y_t - wartość rzeczywista produkcji energii, E_n - dobowa produkcja energii przy pracy turbiny z mocą nominalną.


W metodzie naiwnej prognozę stanowiła produkcja energii z ostatniego dnia sprzed dnia prognozy. W metodzie ekonometrycznej 1 (model jednorównaniowy liniowy dynamiczny) minimalizowaną funkcją był błąd nRMSE z wykorzystaniem metody optymalizacji Newtona (implementacja w arkuszu kalkulacyjnym Excel) do doboru wartości parametrów. W metodzie ekonometrycznej 2, parametry dobierano metodą KMNK (program GRETJ). Metoda „oszacowanie produkcji” to prognoza na podstawie wzoru (2) z podzieleniem uzyskanej wartości przez 4 (wzór szacuje produkcję dla sumy 4 jednakowych turbin) i pomnożeniem przez 24. Prognozy siecią neuronową 1 typu MLP wykonano przy wykorzystaniu programu Statistica. Sieć neuronowa zawierała 6 wejść (czynniki 1,2,3,4,5,6), 8 neuronów ukrytych, funkcje aktywacji w kolejnych warstwach: tangh-lin. Czas uczenia zależny był on algorytmu uczącego (od 600 do 2000 epok). „Zespół 5 sieci neuronowych 1” to metoda, w której przyjęto za prognozy średnie wartości z 5 prognoz wykonanych przy wykorzystaniu 5 różnych algorytmów uczących. „Zespół 5 sieci neuronowych 1 z wagami” to metoda, w której przyjęto za prognozy wartości z 5 prognoz wykonanych przy wykorzystaniu 5 różnych algorytmów uczących z odpowiednimi wagami. Do doboru właściwych wag wykorzystano algorytm optymalizacyjny Newtona, w którym minimalizacji podlegał błąd nRMSE obliczany dla prognoz z wagami z zakresu danych treningowych. Do uczenia pojedynczej sieci neuronowej typu MLP o podanej strukturze (autorska aplikacja – sieć neuronowa 2) użyto także algorytmu PSO w dwóch wariantach [3]: samodzielny dobór wag przez algorytm PSO i algorytm PSO wspomagany algorytmem BP (propagacji wstecznej). Tabela 4 zawiera statystyczne miary oceny jakości estymacji modeli. Rysunki 8, 9, 10 oraz 11 przedstawiają przykładowe prognozy na danych z zakresu weryfikacji w okresie 1.10.2010-31.10.2010.

Tabela 3. Wybrane wyniki prognoz dobowej produkcji energii elektrycznej przez turbinę wiatrową z horyzontem 1 doby

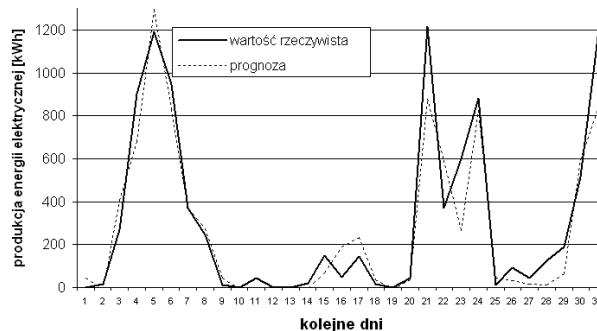
Metoda prognostyczna	Miara błędu	Zakres estymacji	Zakres weryfikacji
Metoda naiwna (4)	nRMSE [%]	8,30	9,38
	wsp.korelacji	0,463	0,534
Metoda ekonometryczna 1 (opt. metodą Newtona) (1,2,3,4,5,6)	nRMSE [%]	3,99	3,80
	wsp.korelacji	0,867	0,926
Metoda ekonometryczna 1 (opt. metodą Newtona) (1,2,3,4,5)	nRMSE [%]	4,19	4,53
	wsp.korelacji	0,842	0,893
Metoda ekonometryczna 2 (opt. metodą KMNK) (1,2,3,4,5,6)	nRMSE [%]	3,94	3,79
	wsp.korelacji	0,870	0,928
Metoda „oszacowanie produkcji” (6)	nRMSE [%]	5,01	5,54
	wsp.korelacji	0,825	0,933
Sieć neuronowa 1 (alg. uczenia: Levenberga-Marquardta)	nRMSE [%]	2,84	3,26
	wsp.korelacji	0,935	0,945
Sieć neuronowa 1 (alg. uczenia: Quasi Newtona)	nRMSE [%]	3,15	3,24
	wsp.korelacji	0,919	0,943
Sieć neuronowa 1 (alg. uczenia: gradienty sprzężone)	nRMSE [%]	3,16	3,13
	wsp.korelacji	0,919	0,948
Sieć neuronowa 1 (alg. uczenia: szybka propagacja)	nRMSE [%]	3,06	3,24
	wsp.korelacji	0,924	0,943
Sieć neuronowa 1 (alg. uczenia: propagacja wsteczna)	nRMSE [%]	3,16	3,35
	wsp.korelacji	0,919	0,941
Zespół 5 sieci neuronowych 1	nRMSE [%]	3,00	3,16
	wsp.korelacji	0,927	0,946
Zespół 5 sieci neuronowych 1 z wagami	nRMSE [%]	2,81	3,27
	wsp.korelacji	0,936	0,946
Sieć neuronowa 2 (alg. uczenia: PSO)	nRMSE [%]	4,08	3,42
	wsp.korelacji	0,863	0,941
Sieć neuronowa 2 (alg. uczenia: PSO+BP)	nRMSE [%]	2,98	3,11
	wsp.korelacji	0,928	0,949



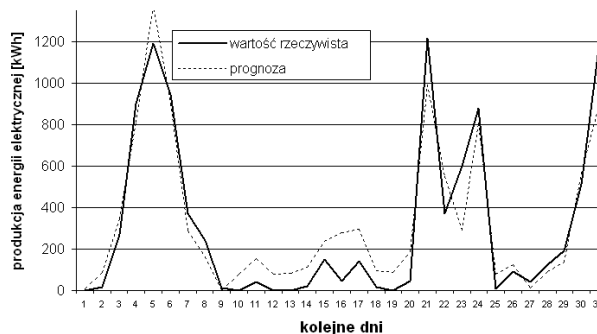
Rys.8. Prognoza wykonana zespołem 5 sieci neuronowych 1 na danych z zakresu weryfikacji 1 (okres od 1.10.2010 do 31.10.2010)



Rys.9. Prognoza wykonana siecią neuronową 2 (alg. uczenia: PSO+BP) na danych z zakresu weryfikacji 1 (okres od 1.10.2010 do 31.10.2010)



Rys.10. Prognoza wykonana siecią neuronową 1 (alg. uczenia: gradienty sprzężone) na danych z zakresu weryfikacji 1 (okres od 1.10.2010 do 31.10.2010)



Rys.11. Prognoza wykonana siecią neuronową 2 (alg. uczenia: PSO) na danych z zakresu weryfikacji 1 (okres od 1.10.2010 do 31.10.2010)

Tabela 4. Statystyczne miary oceny jakości estymacji modeli.

Metoda prognostyczna	s_e	V_e [%]
Metoda ekonometryczna 1 (opt. metodą Newtona) (1,2,3,4,5,6)	188,40	71,81
Metoda ekonometryczna 1 (opt. metodą Newtona) (1,2,3,4,5)	203,77	77,67
Metoda ekonometryczna 2 (opt. metodą KMNK) (1,2,3,4,5,6)	186,17	70,96
Metoda „oszacowanie produkcji” (6)	236,32	90,08
Sieć neuronowa 1 (alg. uczenia: Levenberga-Marquardta)	133,80	51,00
Sieć neuronowa 1 (alg. uczenia: Quasi Newtona)	148,66	56,66
Sieć neuronowa 1 (alg. uczenia: gradienty sprzężone)	149,11	56,83
Sieć neuronowa 1 (alg. uczenia: szybka propagacja)	144,44	55,05
Sieć neuronowa 1 (alg. uczenia: propagacja wsteczna)	149,33	56,92
Zespół 5 sieci neuronowych 1	141,62	53,98
Zespół 5 sieci neuronowych 1 z wagami	132,61	50,55
Sieć neuronowa 2 (alg. uczenia: PSO)	192,36	73,32
Sieć neuronowa 2 (alg. uczenia: PSO+BP)	140,66	53,61

gdzie: s_e - odchylenie standardowe składnika resztowego, V_e - współczynnik zmienności resztowej.

Wykonano testy statystyczne własności najlepszych modeli dla prognoz wygasłych (zakres weryfikacji). We wszystkich testach do weryfikacji hipotez przyjęto 5% poziom istotności, $\alpha=0,05$. Weryfikację normalności rozkładu reszt wykonano testami Doornika-Hansena, Shapiro-Wilka, Lilieforsa oraz Jarque-Bera. Wszystkie testy normalności rozkładu składnika losowego dały wynik negatywny (brak rozkładu normalnego). Weryfikację stacjonarności składnika resztowego wykonano rozszerzonym testem Dickeya-Fullera oraz testem Kwiatkowskiego, Philipsa, Schmidta, Shina. Dla analizowanych najlepszych modeli testy dały wynik

pozytywny (brak negatywnej własności składnika resztowego).

Wnioski

Wykorzystanie do prognoz rzeczywistych danych z danej turbiny wiatrowej o produkcji energii dla danej prędkości wiatru wydaje się korzystniejsze niż wykorzystywanie danych katalogowych producenta do ustalania mocy w zależności od prędkości wiatru. Usunięcie ze zbioru zmiennych objaśniających dobowej wielkości produkcji energii, szacowanej z wykorzystaniem wzoru (2), pogorszyło wyniki prognoz (zakres estymacji oraz zakres weryfikacji). Metoda ekonometryczna 1 oraz 2 uzyskały znacząco gorsze wyniki prognoz (estymatory liniowe). Prognozy uzyskane siecią neuronową 1 z wykorzystaniem różnych algorytmów uczących generowały podobne jakościowo prognozy, aczkolwiek czas uczenia był zdecydowanie najdłuższy dla algorytmu PSO i PSO+BP. Najszybciej uczyły się sieci neuronowe 1 z wykorzystaniem algorytmu Levenberga-Marquardta oraz Quasi Newtona. Zespół 5 sieci neuronowych 1 stworzony z 5 najlepszych sieci neuronowych o różnych algorytmach uczących uzyskał lepsze prognozy w zakresie weryfikacji (dane testowe) niż zespół 5 sieci neuronowych 1 z wagami. Zastosowanie w prognozowaniu zespołów sieci, zamiast pojedynczej sieci neuronowej, wydaje się zatem korzystne. Podobnie dobre rezultaty, na danych testowych, uzyskała sieć neuronowa uczona za pomocą algorytmu PSO+BP.

Autorzy dziękują firmie Globema za udostępnienie danych w ramach projektu 4RES.

LITERATURA

- [1] Baczyński D., Parol M.: *Short-term electric energy consumption forecasting using artificial neural networks aided by evolutionary algorithms*, Przegląd Elektrotechniczny (Electrical Review), 85 (2009), nr.3, 204-207
- [2] Baczyński D., Wasilewski J.: *Krótkoterminowe prognozowanie produkcji energii elektrycznej w systemach fotowoltaicznych*, Rynek Energii, 96 (2011), nr.5, 47-51.
- [3] Baczyński D., *Zastosowanie algorytmu optymalizacji rojem cząstek w procesie uczenia sztucznej sieci neuronowej w prognozowaniu krótkoterminowym*, Rynek Energii, nr 4/2010, 52-56
- [4] Baczyński D., Piotrowski P.: *Analiza skuteczności algorytmów PSO w szacowaniu jakości prognoz godzinowego zapotrzebowania na energię elektryczną wybranych grup odbiorców*, Przegląd Elektrotechniczny (Electrical Review), 87 (2012), nr.11a, 25-29.
- [5] Del Valle Y. et al., *Particle Swarm Optimization: Basic Concepts, Variants and Applications in Power Systems*, *IEEE Transactions on Evolutionary Computation*, vol. 12, no. 2, april 2008, 171-195.
- [6] Dobrzańska I., Dąsał K., Łyp J., Popławski T., Sowiński J.: *Prognozowanie w elektroenergetyce. Zagadnienia wybrane*. Wydawnictwo Politechniki Częstochowskiej, Częstochowa (2002).
- [7] Dudek G.: *Systemy uczące się oparte na podobieństwie obrazów do prognozowania szeregów*. Akademicka Oficyna Wydawnicza Exit, Warszawa (2012).
- [8] Ernst. B. et al.: *Predicting the Wind*, *IEEE Power & Energy Mag.* Nov/Dec.2007, str.79-89.
- [9] Helt P., Parol M., Piotrowski P.: *Metody sztucznej inteligencji w elektroenergetyce*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa (2000)
- [10] Helt P., Parol M., Piotrowski P.: *Metody sztucznej inteligencji. Przykłady zastosowań w elektroenergetyce*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2012.
- [11] Jing S. et al.: *Evaluation of hybrid forecasting approaches for wind speed and power generation time series*, *Renewable and Sustainable Energy Reviews*, January 2012, volume 16 (5).
- [12] Kacejko P., Wydra M.: *Energetyka wiatrowa w Polsce – realna ocena możliwości wytwórczych*, *Rynek Energii*, 6/2010, 100-104.
- [13] Malko J.: „Predykcja mocy wytwórczych elektrowni wiatrowych”, *Przegląd Elektrotechniczny*, 84 (2008), nr.9, 65-67.
- [14] Malko J.: *Zastosowanie prognozowania krótkoterminowego i inteligentnego sterowania predykcyjnego do zarządzania pracą elektrowni wiatrowych*, *Nowa Energia*, 30 (2012), nr.6, 40-44.
- [15] Methaprayoon, K. et.al.: *An Integration of ANN Wind Power Estimation Into Unit Commitment Considering the Forecasting Uncertainty*, *Industry Applications*, *IEEE Transactions on*, November 2007, volume 43
- [16] Piotrowski P.: *Analiza statystyczna danych mających wpływ na produkcję energii elektrycznej przez farmę wiatrową oraz przykładowe prognozy krótkoterminowe*, *Przegląd Elektrotechniczny (Electrical Review)*, 88 (2012), nr.3a, 161-164.
- [17] Piotrowski P.: *Analiza statystyczna oraz prognozy dobowej produkcji energii przez farmę wiatrową z horyzontem 1 doby*, *Elektro.info* nr. (103) 2012, nr.4, 48-52.
- [18] Piotrowski P.: *Analiza statystyczna oraz prognozy godzinowej produkcji energii przez elektrownię wiatrową z horyzontem 1 godziny*, *Elektro.info*, 103 (2012), nr.3 90-95.
- [19] Piotrowski P.: *Prognozowanie krótkoterminowe godzinowych obciążeń w spółce dystrybucyjnej z wykorzystaniem sieci neuronowych – analiza wpływu doboru i przetworzenia danych na jakość prognoz*, *Przegląd Elektrotechniczny (Electrical Review)*, 83 (2007), nr.7-8, 40-43.
- [20] Piotrowski P.: *Neural network with genetic algorithms for the monthly electric energy consumption and peak power middle-term forecasting*, *Journal of Applied Computer Science*, *JACS* 2002, vol.10, No. 1, Technical University Press Łódź (2002), 105-116.
- [21] Piotrowski P.: *“The optimum selection of data for forecasts of demand on electric energy consumption for different time horizons”*, 2nd International Youth Conference on Energetics (2009), Budapeszt 4-6 czerwca 2009.
- [22] Popławski T.: *Wybrane zagadnienia prognozowania długoterminowego w systemach elektroenergetycznych*, Wydawnictwo Politechniki Częstochowskiej, Częstochowa 2012.
- [23] Popławski T., Dąsał K., Łyp J., Szeląg P.: *Zastosowanie modeli ARMA do przewidywania mocy i energii pozyskiwanej z wiatru*, *Polityka Energetyczna*, 13 (2010), nr.2, 511-523.
- [24] Popławski T., Dąsał K., Łyp J.: *Problematyka prognozowania mocy i energii pozyskiwanych z wiatru*, *Polityka Energetyczna*, 12 (2009), 2/2, 385-400,
- [25] Popławski T., Dąsał K., Rusek K.: *Predykcja dobowej produkcji energii elektrycznej na farmie wiatrowej*, *Rynek Energii*, 1 (2009), 319-323,
- [26] Riccardo P., *Analysis of the Publications on the Applications of Particle Swarm Optimisation*, *Journal of Artificial Evolution and Applications*, vol. 2008, Article ID 685175, 10 pages, 2008. doi:10.1155/2008/685175.
- [27] Sideratos, G: *An Advanced Statistical Method for Wind Power Forecasting*, *Power Systems*, *IEEE Transactions on*, February 2007, volume 22.
- [28] Venayagamoorthy G.K., Rohring K., Erlich I.: *Short term wind Power Forecasting and Intelligent Predictive Control*, *IEEE Power & Energy Mag.*, vol.10, no.3, Aug. (2011), 71-78.
- [29] Trojanowski K., *Metaheurystyki praktycznie*, Wydanie 2, poprawione, Wyższa Szkoła Informatyki Stosowanej i Zarządzania, Warszawa 2008.
- [30] <http://www.kulak.com.pl>
- [31] <http://anemos.cma.fr/>

Autorzy: dr inż. Dariusz Baczyński, Politechnika Warszawska, Instytut Elektroenergetyki, ul. Koszykowa 75, 00-662 Warszawa, E-mail: dariusz.baczynski@ien.pw.edu.pl,
dr inż. Paweł Piotrowski, Politechnika Warszawska, Instytut Elektroenergetyki, ul. Koszykowa 75, 00-662 Warszawa, E-mail: pawel.piotrowski@ien.pw.edu.pl