

Dr hab. inż. Elżbieta BOGALECKA  
Politechnika Gdańska  
Wydział Elektrotechniki i Automatyki  
Mgr inż. Tomasz RUBANOWICZ  
ENERGA-Obrót SA

## **MODEL FIZYKALNY CZY NEURONOWY? – NARZĘDZIA DO PREDYKCJI MOCY WYTWARZANEJ PRZEZ ELEKTROWNIE WIATROWE**

*Streszczenie: Ustawowy obowiązek prognozowania mocy dotyczy właścicieli elektrowni wiatrowych o mocy znamionowej powyżej 50 MW. Ze względu na coraz większą ilość przyłączonych elektrowni wiatrowych do krajowej sieci elektroenergetycznej, zapis ten może ulec zmianie, obejmując źródła wiatrowe mniejszej mocy. Obecnie największa pojedyncza turbina wiatrowa w Polsce ma generator o mocy 3 MW, natomiast największy zespół elektrowni wiatrowych (farma wiatrowa) ma moc znamionową 120 MW. Moc pojedynczych siłowni wiatrowych również jest prognozowana, lecz przez Operatorów Sieci oraz Spółki Obrótowe. W artykule poruszono problematykę doboru modelu prognozowania generacji mocy wytwórczej dla pojedynczej turbiny wiatrowej. Rozważono model prognostyczny fizyczny (analityczny) i neuronowy pod kątem odpowiedzi na pytanie: czy przy zastosowaniu tych modeli możliwe jest uzyskanie dokładniejszych prognoz mocy źródeł wiatrowych i w jakim stopniu jakość krótkoterminowych lokalnych prognoz meteorologicznych wpływa na pracę modeli?*

## **PHYSICAL MODEL OR ARTIFICIAL NEURON NETWORK? – TOOLS FOR FORECASTING OF THE WIND POWER GENERATION**

*Abstract: Currently, the largest single wind turbine generator in Poland is about 3MW capacity, while the largest group of wind turbines is the rated power of 120MW. This paper presents the problem of selection of the forecasting model generation of generation capacity for a single wind turbine. Considered the physical forecast model (analytical) and for neural responses to the question whether the use of these models, it is possible to obtain more accurate predictions of wind power sources, and to what extent, the quality of local short-term weather forecasting models affect the work?*

### **1. WPROWADZENIE**

Rozwój rynku energii elektrycznej oraz prywatyzacja sektora elektroenergetyki sprawiły, że uczestnik rynku ma możliwość samodzielnego podejmowania większości decyzji strategicznych dotyczących kupna i sprzedaży energii elektrycznej wraz z ponoszeniem odpowiedzialności za niewywiązanie się z umów zawieranych na rynku [8]. Charakter pracy elektrowni wiatrowych (urządzeń pasywnych) wprost zależy od warunków pogodowych i wymaga profesjonalnych narzędzi do nadzorowania generacji mocy. Od połowy lat 90 na rynku pojawiło się wiele narzędzi do prognozowania mocy wytwórczej elektrowni wiatrowych, w tym m.in. WindFarmer, AWPPS (Advanced Wind Power Prediction Tool), WPPT (Wind Power Prediction Tool), WASP (Wind Atlas Analysis and Application

Program) itp., które z czasem były modyfikowane. Zasady funkcjonowania narzędzi do predykcji opisane są szczegółowo w literaturze [2-4, 6, 9, 11].

Niezależnie od wybranego modelu, szacowanie produkcji energii elektrycznej odbywa się w oparciu o numeryczne prognozy pogody. Z uwagi na zmienność wielkości meteorologicznych, tj. prędkości i kierunku wiatru, temperatury oraz ciśnienia powietrza, ale także zróżnicowanie rzeźby terenu wokół dużej elektrowni wiatrowej (DTW), predykcja generacji mocy jest dość złożonym zagadnieniem [1, 5, 7]. Obecnie wyróżnia się trzy zasadniczo odmienne podejścia do estymacji mocy elektrowni wiatrowych (tabela 1).

Tabela 1. Metody prognozowania


Metoda	Zalety	Wady
Fizykalna	Łatwa do obliczeń, nie wymaga specjalistycznego oprogramowania ani komputerów dużej mocy	Dobór współczynników wagowych przez człowieka, wymagana wiedza ekspercka
Statystyczna	Wykorzystuje trendy i wahania sezonowe, cykliczne i przypadkowe, daje możliwość ustalenia zmienności generacji mocy względem zjawisk meteorologicznych	Duży wpływ wahań przypadkowych na sporządzane prognozy, liczna baza danych
Neuronowa	Nie wymaga ingerencji człowieka w dobór współczynników wagowych, ma umiejętność generalizacji, sieci potrafią prawidłowo reagować na nowe dane, nawet zaszumione	Długi okres uczenia sieci, trudności przy wyborze struktury sieci dla modelu, wymagana duża moc obliczeniowa komputerów

Do badań wykorzystano rzeczywiste dane produkcyjne Dużej Turbiny Wiatrowej (DTW) o mocy znamionowej 2 MW, zlokalizowanej w północnej części kraju. Dane produkcyjne DTW zostały zarejestrowane bezpośrednio w gondoli, z krokiem 10-minutowym przez okres 1 tygodnia (w różnych porach roku). Jednostka mocy została unormowana (w przedziale od 0 do 1). Do analizy wybrano te okresy produkcyjne, między którymi pojawiła się największa różnica w produkcji energii elektrycznej (latem i zimą). Zauważono, że zimą, ze względu na większą gęstość powietrza, produkcja energii elektrycznej jest wyższa niż w okresie letnim. Z obserwacji wynika także, że zimą wiatry są bardziej stabilne niż latem, co zostało przedstawione w dalszej części pracy. Dostrzeżono również, że kierunek wiatru, w szczególności jego dynamika zmian, ma istotny wpływ na generację mocy (charakterystykę mocy). Niezbędnym narzędziem do szacowania generacji mocy jest charakterystyka mocy (krzywa), którą udostępniają producenci elektrowni wiatrowych z zastrzeżeniem określonych warunków meteorologicznych.


## 2. RZECZYWISTA CHARAKTERYSTYKA TURBINY WIATROWEJ

Zmienność generacji mocy czynnej wynika z wartości chwilowej prędkości wiatru, a nie z mocy znamionowej urządzenia. Z badań wynika, że rzeczywista krzywa mocy pojedynczej DTW różni się od teoretycznej [10]. Na rysunek 1 pokazano rzeczywistą (czarne kropki) i teoretyczną (niebieskie kropki) moc DTW w funkcji prędkości wiatru w okresie zimowym, gdy odchylenie punktów pracy od charakterystyki producenta jest stosunkowo niewielkie. Dzieje się tak dzięki temu, że w tym okresie kierunek (rys. 3) i dynamika wiatru są bardziej stabilne niż w okresie letnim. Zjawisko dużego odchylenia występuje przeważnie w okresie letnim, kiedy wiatry są słabsze, a prędkość i kierunek wiatru zmieniają się bardzo dynamicznie, co pokazano na rys. 4. Porównanie rysunków 3 i 4 z odpowiednimi rysunkami 1 i 2 wskazuje na korelację pomiędzy zmiennością kierunku wiatru a odchyleniem mocy od wartości katalogowej. W okresach, gdy zmienność kierunku jest duża, odchyłka mocy jest

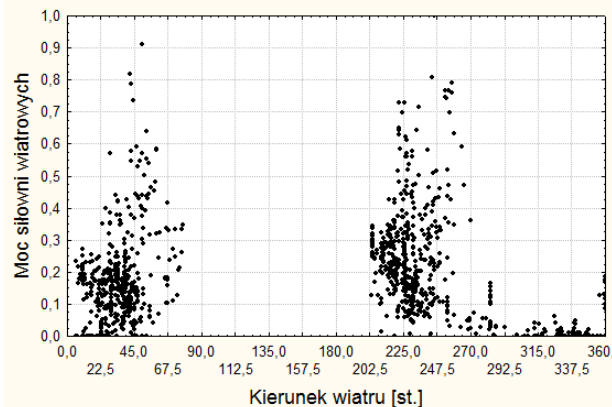
zdecydowanie istotna, natomiast przy wietrze o stałym kierunku, krzywa mocy rzeczywista i teoretyczna pokrywają się. Przyczyny można upatrywać w sposobie reakcji układu regulacji i zabezpieczeń (kąta ustawienia łopat i ukierunkowania gondoli) na zaburzenie, w postaci dużej zmienności wartości kierunku wiatru. Rzeczywista charakterystyka mocy, przez większą część roku, nie pokrywa się z teoretyczną.




Rys. 1. Charakterystyka mocy DTW w funkcji prędkości wiatru (pomiary w okresie zimowym, stabilne wiatry) [10]



Rys. 2. Charakterystyka mocy DTW w funkcji prędkości wiatru (pomiary w okresie letnim, duża zmienność wiatru) [10]




Rys. 3. Róża rzeczywistych kierunków wiatru na gondoli DTW (pomiary w okresie zimowym) [10]



Rys. 4. Róża rzeczywistych kierunków wiatru na gondoli DTW (pomiary w okresie letnim) [10]

Analiza wykazała (rys. 5), że wartość prędkości wiatru ( $V_{wM50}$ ) zmienia się przy zmianie kierunku wiatru ( $K_{wM50}$ ), co skutkuje kilkuprocentowym spadkiem generacji mocy ( $P_{cReal}$ ).



Rys. 5. Wpływ zmian kierunku wiatru ( $K_{wM50}$ ) i prędkości wiatru ( $V_{wM50}$ ) na moc ( $P_{cReal}$ ) (pomiary w okresie letnim)

### 3. ZWIĄZKI POMIĘDZY ZMIENNYMI METEOROLOGICZNYMI

Prognozy pogody wykonywane są w oparciu o dane pomiarowe ze stacji meteorologicznych, przez krajowe instytuty meteorologiczne. Przyczyną słabej jakości prognoz jest to, że maszty meteorologiczne są najczęściej dużo niższe (średnio na wysokości 30 m n.p.g.) niż konstrukcje turbin wiatrowych (średnio 80 m n.p.g.), a dodatkowo są posadowione na innej wysokości i oddalone od źródeł wiatrowych (rys. 6). Obecna liczba masztów meteorologicznych w Polsce jest niewystarczająca, aby zaspokoić potrzeby jakościowe (o najwyższej dokładności) prognoz pogody dla energetyki wiatrowej. Ze względu na słabo rozwinięty system meteorologiczny, wartości prognozy prędkości wiatru ze stacji meteorologicznej muszą być ekstrapolowane na wysokość i odległość siłowni wiatrowych. Istnieje wiele metod ekstrapolacji prędkości wiatru na poziom piasty. Poniżej przedstawiono wzór uzależniający prędkości wiatru od tzw. długości szorstkości terenu.


$$V_h = v \cdot \frac{\ln \frac{h}{n}}{\ln \frac{h_0}{n}} \quad (1)$$

gdzie:  $v_h$  – prędkość wiatru na wysokości  $h$  [m/s],  $v$  – prędkość wiatru na wysokości  $h_0$  [m/s],  $h_0$  – wysokość pomiaru prędkości wiatru [m],  $h$  – wysokość, dla której obliczana jest prędkość wiatru [m],  $n$  – długość szorstkości terenu.

Długość szorstkości  $n$  jest definiowana jako wysokość nad poziomem ziemi, na której prędkość wiatru jest zredukowana do wartości 0 m/s, na skutek oddziaływania podłoża na ruchy powietrza.

Głównymi wartościami wejściowymi modelu prognostycznego są przewidywana prędkość i kierunek wiatru. Od ich dokładności zależy jakość prognozy mocy. Dokładność prognozy prędkości wiatru obarczona jest błędem, ponieważ maszty pomiarowe nie są posadowione bezpośrednio przy DTW.

W podejściu fizykalnym dużą zaletą jest to, że nie trzeba gromadzić danych historycznych pracy obiektu, aby model działał poprawnie. W przypadku podejścia neuronowego bez danych historycznych model nie będzie prawidłowo funkcjonował. W modelu fizykalnym najczęściej uwzględnia się tylko najważniejszą wartość: prędkość wiatru. Prędkość wiatru mierzona na gondoli turbiny wiatrowej i na maszcie meteorologicznym może różnić się od 4 m/s, a nawet do 8 m/s w odległości zaledwie 4 km. Wpływ na taką różnicę ma w zdecydowanej mierze ukształtowanie terenu wokół turbiny wiatrowej.



Rys. 6. Rozmieszczenie i odległość masztu meteo od DTW

Na rysunku 7 pokazano przypadkowe rzeczywiste prędkości wiatru zmierzone na gondoli o wysokości 80 m i z masztu na farmie o wysokości 50 m odległego o ok. 4-5 km. Współczynnik korelacji Pearsona  $r$  (na rys. 9 i 10), wyliczono w oparciu o próbę losową. Wyniki przedstawiono w tabeli 2 przy liczności próbki  $N = 141$ .


Tabela 2. Korelacja prędkości i kierunku wiatru

Zmienna	Współczynnik korelacji
Vw na maszcie meteo / Vw na gondoli	0,87
Kw na maszcie meteo / Kw na gondoli	0,96


Jak widać, prędkości wiatru są silnie skorelowane. Współczynnik korelacji rzędu 0,87 wynika m.in. z niewielkiej odległości masztu meteorologicznego od DTW oraz ukształtowania terenu. Odległość ta nie przekracza 10 km. Przebadano również kierunek wiatru, który nie jest skorelowany z mocą DTW, a jak się okazało – wpływa na wartość mocy. Jak widać, pomiędzy kierunkami wiatru również zachodzi korelacja (wsp. korel. wynosi 0,96) i jest znacznie wyższa niż w przypadku obu prędkości wiatru. Oznacza to, że wartość kierunku wiatru na gondoli względem kierunku na maszcie, pomimo różnicy odległości i wysokości, nie jest istotna. W tym przypadku obie wartości można potraktować jako jedną wartość zastępczą.

W sytuacji awarii anemometru na gondoli będzie można zasugerować się pomiarami kierunku wiatru na maszcie meteorologicznym. Omawianą sytuację pokazuje wykres rorzutu (rys. 10). Dokładna prognoza kierunku wiatru może zwiększyć dokładność prognozy mocy DTW. Kierunek wiatru ma wpływ na przesłonięcie i pionowy profil wiatru. Widoczne przesunięcie o ok. 15 stopni może wynikać z przyjętego na obracającej się gondoli punktu odniesienia.


Podmioty przygotowujące prognozy pogody dla źródeł wiatrowych muszą posiadać podstawowe informacje o obiekcie, m.in. wysokość i odległość turbin wiatrowych od stacji meteorologicznej, szorstkość terenu wokół stacji metrologicznej (uwzględniające wszelkie wysokie przeszkody, w tym budynki), jak i elektrowni wiatrowych.




Rys. 7. Przebieg rzeczywistej prędkości wiatru: a) czerwona linia – na DTW, b) niebieska linia – na maszcie meteo



Rys. 8. Przebieg rzeczywistego kierunku wiatru: a) czerwona linia – na gondoli DTW, b) niebieska linia – na maszcie meteo



Rys. 9. Korelacja zmiennej prędkości wiatru na gondoli DTW i maszcie meteo



Rys. 10. Korelacja zmiennej kierunku wiatru na gondoli DTW i maszcie meteo

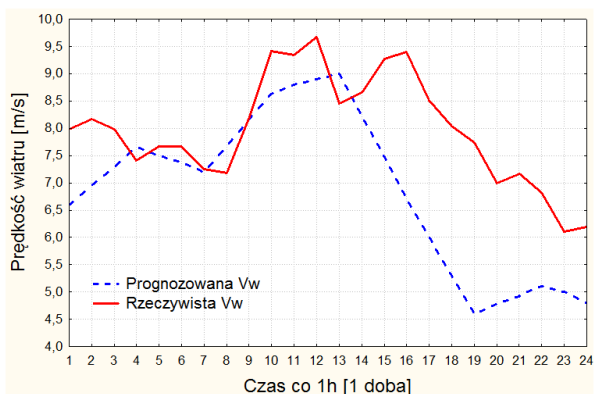
#### 4. PROGNOZY WIATRU

Najlepszymi prognozami pogody dla elektrowni wiatrowych są lokalne numeryczne prognozy krótkoterminowe. Prognozy krótkoterminowe opracowane są na podstawie (a) analizy danych meteorologicznych, (b) analizy zdjęć satelitarnych, (c) analizy innych aktywnych i pasywnych metod teledetekcyjnych, (d) na podstawie modeli numerycznych. Modele numeryczne najczęściej oparte są na metodach statystycznych lub na podstawowych zasadach fizyki przepływu powietrza. Ze względu na ograniczoną liczbę danych pomiarowych, modele prognostyczne oceniono dla prędkości wiatru, która znacznie wpływa na generację mocy. Trudno jest uzyskać dobrą prognozę pogody z odchyleniami na poziomie 5%, m.in. najczęściej z powodu dużej odległości, jaka dzieli stację meteo od badanego obiektu. Ocenia się, że najlepsze prognozy uzyskuje się do 10 km, z błędem rzędu 20% [5]. W przypadku badanej DTW odległość masztu meteorologicznego nie jest większa niż 10 km, dzięki czemu uzyskano dobre wyniki prognozy mocy, pokazane w dalszej części. Analiza pomiędzy pomiarem a prognozą (rys. 11 i 12) prędkości i kierunku wiatru pokazuje, że współczynnik korelacji między wielkościami jest znacznie niższy niż przy rzeczywistych pomiarach. Świadczy to o tym, że prognozy pogody są niedokładne, a pomimo małej odległości masztu od DTW widać, że nie tak łatwo jest uzyskać dobrą prognozę pogody (tabela 3).


Tabela 3. Korelacja prognozowanej i rzeczywistej prędkości wiatru

Zmienna	Współczynnik korelacji
Vw prognozowana / Vw rzeczywista	0,67
Kw prognozowany / Kw rzeczywisty	-0,32

Przy współczynniku korelacji (na poziomie 0,67) trudno jest uzyskać prognozę mocy z mniejszym błędem niż 30%. Z badań wynika, że wraz ze wzrostem współczynnika korelacji prędkości wiatru (dążącym do jedynki) błąd prognozy mocy maleje. Pojawiająca się korelacja ujemna występuje wtedy, gdy wzrostowi wartości jednej zmiennej odpowiada spadek średnich wartości drugiej zmiennej. Współczynnik korelacji jest w tym przypadku znacznie niższy niż prędkości wiatru.



Rys. 11. Przebieg prognozowanej i rzeczywistej prędkości wiatru DTW, w ciągu doby




Rys. 12. Przebieg zmian kierunku wiatru prognozowanego i rzeczywistego DTW, w ciągu doby


## 5. PORÓWNANIE WYNIKÓW PROGNOZOWANIA MOCY

Na rysunkach 13 i 14 przedstawiono wyniki prognozowania mocy DTW przy użyciu dwóch narzędzi matematycznych. Czerwonym kolorem oznaczono prognozę mocy przy użyciu modelu neuronowego (SSN), czarnym – predykcję mocy modelu fizykalnego (MetAnalit), natomiast granatowym – rzeczywistą produkcję mocy (PcReal).

Na rysunku 13 przedstawiono przykład dobrej prognozy mocy, uzyskanej dzięki zbliżonej prognozie prędkości wiatru do rzeczywistej. Na rysunku 14 pokazano przykład predykcji mocy w sytuacji słabej prognozy prędkości wiatru. Przeprowadzone testy na wybranych modelach prognostycznych wykazały, że bez względu na zastosowaną metodę, bez dobrej prognozy pogody, trudno jest dokładnie przewidzieć produkcję energii elektrycznej.



Rys. 13. Prognoza mocy DTW dla dobrej prognozy prędkości wiatru



Rys. 14. Prognoza mocy DTW dla złej prognozy prędkości wiatru

W tabeli 4 przedstawiono wyniki korelacji prognozowanej i rzeczywistej mocy DTW przy wykorzystaniu dokładnej i błędnej prognozy pogody. Na podstawie korelacji prognozowanej mocy (przedstawionej w tab. 4) i:

- dokładnej prognozowanej prędkości wiatru, o współczynniku 0,98 (dla SNN) i 0,97 (dla MetAnalit) oraz
- błędnej prognozie prędkości wiatru, o współczynniku 0,38 (dla SSN) i 0,19 (dla MetAnalit)

można wnioskować, że model neuronowy lepiej odzwierciedla cechy osobowościowe obiektu niż model fizykalny.

Tabela 4. Korelacja prognozowanej i rzeczywistej mocy

Zmienna	Przypadek 1	Przypadek 2
$E_{real}$	0,65	0,71
$E_{SSN}$	0,63	0,80
$E_{FIZ}$	0,62	0,78
Błąd prognozy: $\frac{E_{real} - E_{SSN}}{E_{real}}$	-5%	9%
Błąd prognozy: $\frac{E_{real} - E_{FIZ}}{E_{real}}$	-2%	-3%

## 6. PODSUMOWANIE

Mając do wyboru model prognostyczny, należy rozważyć kilka istotnych aspektów, tj. możliwości techniczne pozyskiwania danych wejściowych do modelu z zewnętrznego źródła, oczekiwane rezultaty prognozy mocy (inwestycja w prosty model, to ryzyko większych błędów), koszty wdrożenia w firmie, wymagania sprzętowe i serwisowe koszty utrzymania, zatrudnienie i przeszkolenie pracownika, oraz inne niewymienione.

Po uwzględnieniu powyższych wskazówek bez rozbudowy systemu meteorologicznego przystosowanego do potrzeb energetyki wiatrowej, uzyskanie dokładnej prognozy mocy będzie utrudnione. Nawet najlepsze modele prognostyczne mocy nie są idealne. Wiadomo jednak, że czym bardziej zaawansowany model tym prognozy mocy są dokładniejsze. Wyniki uzyskane przy pomocy modelu neuronowego (o różnych porach roku – latem i zimą), tj. w przypadku dokładnej jak i błędnej prognozy prędkości wiatru, okazały się lepsze od wyników modelu fizycznego. Model neuronowy uzyskał w obu przypadkach lepsze wyniki, w pierwszym przypadku o 34%, natomiast w drugim o 1%. Model neuronowy lepiej radzi sobie w przypadku prognoz pogody obarczonych większym błędem. Błędy prognozy mocy można zmniejszyć, poprzez uwzględnianie dodatkowych aspektów, których w testach nie brano pod uwagę, np. uzupełniając model prognostyczny o pionowy profil wiatru lub szorstkość terenu. Mając do wyboru model analityczny lub model neuronowy, zdecydowanie warto rozważyć model wykorzystujący sztuczną inteligencję.

## LITERATURA

- [1] Bogalecka E., Rubanowicz T.: *Modele farmy wiatrowej na potrzeby prognozowania mocy*, Konferencja Naukowo-Techniczna SENE 2011, Łódź 2011.
- [2] Dobrzyński K.: *Przegląd systemów przeznaczonych do predykcji mocy wytwarzanej w farmach wiatrowych*, Aktualne Problemy w Elektroenergetyce, APE 2009, Jurata 2009.
- [3] Kariniotakis G.N., Marti I., Nielsen T.S., Giebel G., Tambke J., Waldl I., Usaola J.: *Advanced Short-term Forecasting of Wind Generation – ANEMOS* (Contract No ENK5-CT-2002-00665, 2002-2006, 24 partners, 7 countries), European Commission under the FP5 R&D Project ANEMOS: IEEE Trans. On Power Systems, 2006.
- [4] Madsen H., Nielsen Aalborg H., Nielsen T.S.: *A tool for predicting the wind power production of off-shore wind plants*, DK-2800 Kongens Lyngby, Richard Petersens Plads, Building 321, Denmark: Technical University of Denmark, Informatics and Mathematical Modelling, 2006.
- [5] Miotk M.: *Wykorzystanie prognoz pogody w energetyce wiatrowej*, praca magisterska, Politechnika Gdańska, Gdańsk 2009.



- [6] Milligan M., Schwartz M.N., Wan Y.: *Statistical Wind Power Forecasting for U.S. Wind Farms*, 17th Conference on Probability and Statistics in the Atmospheric Sciences, Washington, 2004.
- [7] Parkers J., Tindal A.: *Forecasting Short Term Wind Farm Production in Complex Terrain*, Garrard Hassan and Partners Ltd, [www.gl-garradhassan.com](http://www.gl-garradhassan.com)
- [8] Prawo energetyczne, Ustawa z dnia 10 kwietnia 1997 r. Prawo energetyczne na dzień 9 sierpnia 2010 r. (tekst ujednolicony w Biurze Prawnym URE), Warszawa 1 stycznia 2012 r.
- [9] Rubanowicz T.: *Metody predykcji produkcji mocy parku wiatrowego*, Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej, nr 25, Gdańsk 2008.
- [10] Rubanowicz T., Bogalecka E.: *Neuronowy model mocy farmy wiatrowej*, s. 579-586, Czasopismo Naukowo-Techniczne: Mechanik, Jurata 2010.
- [11] Sánchez I.: *Short-term prediction of wind energy production*, International Journal of Forecasting, vol. 22, Issue 1, 2006, pp. 43-56.

