

Effective Short-term Forecasting of Wind Farms Power

Authors

Elżbieta Bogalecka
 Tomasz Rubanowicz

Keywords

wind farm, power, model, prediction

Abstract

Forecasting a specific wind farm's (WF) generation capacity within a 24 hour perspective requires both a reliable forecast of wind, as well as supporting tools. This tool is a dedicated model of wind farm power. This model should include not only general rules of wind to mechanical energy conversion, but also the farm's specific features. There are many factors that influence a farm's generation capacity, and any forecast of it, even with an accurate weather forecast, carries error. This paper presents analytical, statistical, and neuron models of wind farm power. The study is based on data from a real wind farm. Most attention is paid to the neuron models, due to a neuron network's capability to restore farm-specific details. The research aims to answer the headline question: whether and to what extent a wind farm's power can be forecast short-term?

DOI: 10.12736/issn.2300-3022.2015301

Introduction

Wind farm output forecasting requires the weather (mainly wind) forecast and appropriate tools to support the output forecasting. This tool is a dedicated wind farm power model. Using the generally known principles of wind energy conversion into mechanical energy and electricity the output power of a single turbine and entire farm alike can be estimated. A source of output estimate error is failure to take account of a particular farm's specific characteristics. These characteristics are specific to site location, site terrain topology, farm expanse and topology, and the turbine and its control type. There are so many factors that influence a farm's output, and any forecast of it, even with an accurate weather forecast, is difficult and prone to error. An important error minimising factor is the operator's experience.

The reference literature is extensive and describes a multitude of output forecasting methods [3, 6, 7]. In addition, there are several dedicated software tools [4, 5] available on the market.

WF power models can be divided into analytical models – based on physical principles of wind energy conversion into electricity, behavioural models – based on artificial intelligence methods (e.g. artificial neural networks), and statistical models. Each of these models has different design, accuracy, computational complexity and scope of application.

This paper presents basic forecasting methods and assesses their accuracy. The analysis is based on data from actual wind farms in northern Poland.

Further in this paper are described the basics of wind turbine operation and factors affecting its output power; physical, statistical and neural models, and their verification and evaluation.

Wind turbine and farm

The main task of a wind turbine is to generate electricity. Today's large wind turbines are equipped with complex control systems to ensure the processing of wind energy into mechanical energy with maximum efficiency. This is possible by connecting the generator to the power grid through a power electronic converter, and owing to the blades' pitch control. Wind turbine output power is described with the formula:

$$P = \frac{1}{2} \rho A V^3 C_p \quad (1)$$

where:

V – wind speed, A – wind turbine swept area, ρ – air density, C_p – power coefficient.

Power coefficient C_p determines the efficiency of the airflow energy conversion into mechanical energy, and depends on the blade design and the method of turbine (blade pitch, wind turbine rotation) control. To maintain the maximum power coefficient, a turbine has to rotate at variable speed depending on the wind speed. Most of today's large turbines operate at variable speed owing to the converter, which is usually a voltage source inverter. At a wind speed below the rating, the generator and wind turbine rotate at the speed that ensures the maximum efficiency. At a higher wind speed, the generator output is limited to its rated value, and the blade pitch control system reduces the lifting force so that the turbine's rotational speed is maintained at a near constant value. Therefore, the turbine operates with a variable power coefficient C_p , maximum in the optimum operating range ($V < V_n$) and decreasing in the output reduction

range ($V > V_n$). The basic value, in respect to which the blade pitch and the turbine output power are adjusted (in the control system), is not the wind speed, but the angular speed of the generator. The output power curves as functions of wind speed presented in turbine catalogues are not their natural characteristics, but they arise from the turbine control method. Published characteristics are obtained on the basis of measurements, after having been brought to standard conditions [1]. Actual characteristics are fraught with uncertainty. Deviation of actual turbine output from its catalogue value results from, for instance, other temperature and pressure or density, i.e. air density or wind dynamics.

A wind farm consists of a few to several dozen turbines, usually of the same type, deployed throughout an extensive area. Each turbine operates at slightly different wind conditions, and therefore at a different point on its operating curve. These conditions are determined by local wind conditions, i.e. wind speed and direction, nacelle elevation above the ground, location in the farm, and shadowing effect due to the location in relation to other turbines and the wind direction. These differences can be quite large. Fig. 1 shows the exemplary wind speed waveforms

and output powers obtained under natural conditions for three turbines in a vast wind farm. Wind speed sensors are placed on nacelles behind turbines, so they do not measure the inflowing wind speed. This contributes to the explanation why rotor speed is a more reliable input for the control system than wind speed. Farm output is the sum of individual turbine outputs. Fig. 2 shows a set of operating points of a wind farm (from Fig. 1), i.e. the farm output as a function of average wind speed, obtained on the basis of 10-minute averages from one week.

Average wind speed is the arithmetic average of wind speeds from all sensors on nacelles. Fig. 2a shows that despite different conditions of each turbine's operation (Fig. 1) the farm output is burdened with a small uncertainty (here max. ca. 8%), which means that each turbine's control system operates precisely, and that in the measurement period similar conditions (air density, wind direction variation) prevailed. With large wind direction variations (Fig. 2b) the uncertainty (here max. 14.5%) of the farm output is also larger. These observations are important for forecasting wind farm output.

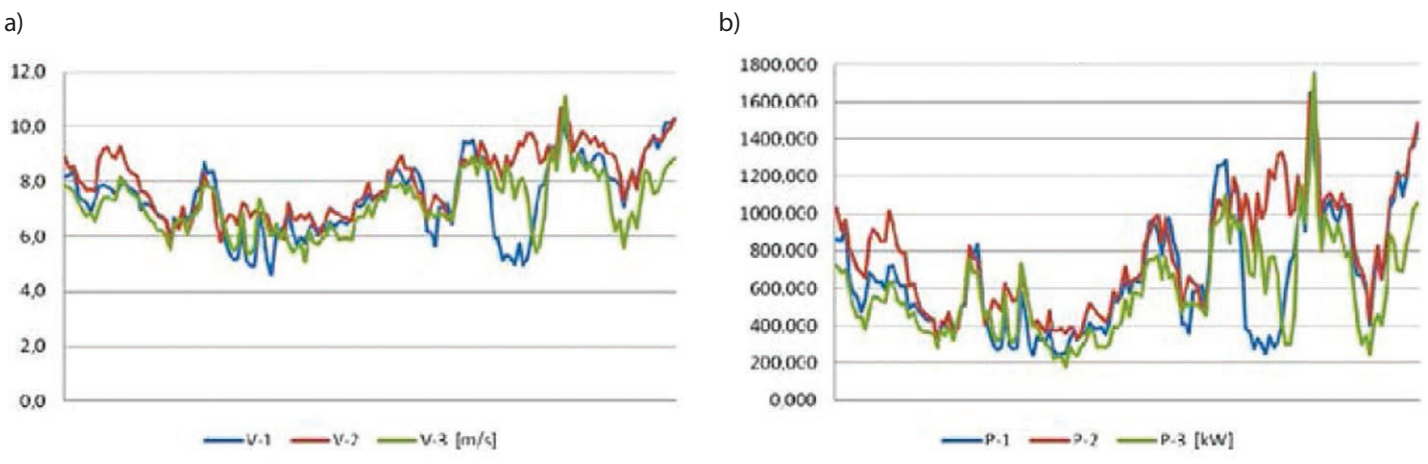


Fig. 1. Wind speeds and wind turbine output powers in a vast wind farm (for the period of one day)

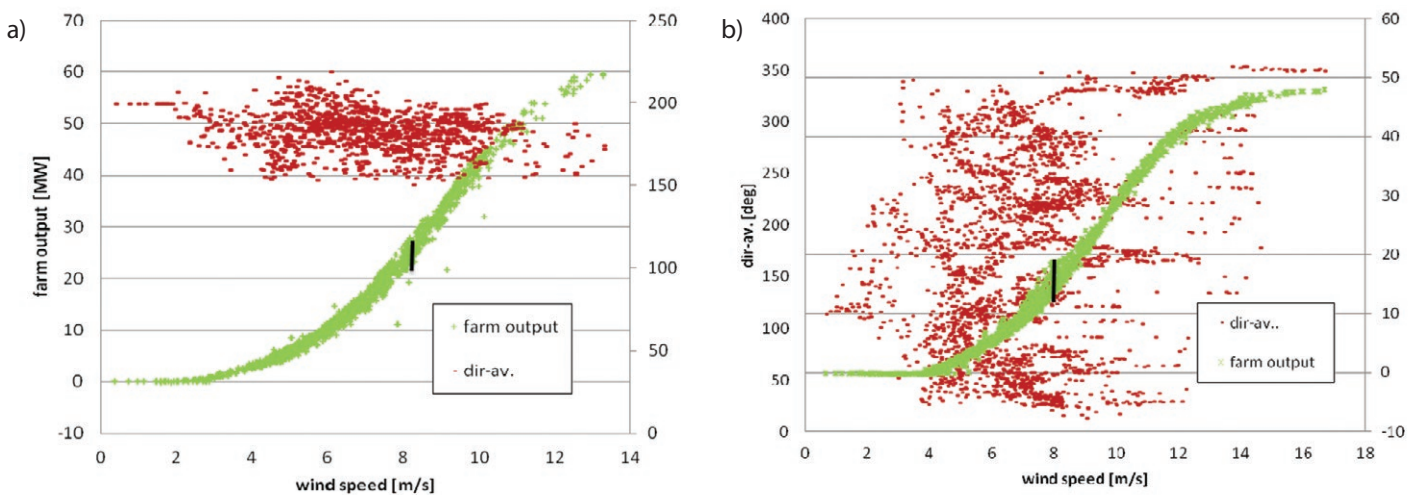


Fig. 2. WF output power and average wind direction as a function of average wind speed a) wind farm with output of ca. 60 MW, in one week, b) wind farm with output of ca. 50 MW, in three weeks

Physical model of wind farm power

Under the assumption that farm output power as a function of wind speed is the scaled characteristics of a single turbine, the farm power's simple model can be developed. On the basis of equation (1) and catalogue characteristics of a farm's wind turbines, the output power of a single windmill can be calculated for a specific wind speed. A wind farm output, however, is not the mere multiple of the single turbine output. Apart from the different wind conditions, certain farm specific features, e.g. power reduction due shadowing effect or different nacelle elevations, should be included in the calculation. Each farm has its own individual characteristics that cannot be easily algorithmised. A WF model should take into account the above factors: height above the ground, shadowing, wind condition variations throughout farm site. Farm output power may be determined analytically from formula (2) or (3):

$$P_z = \sum_{i=1}^n P_i = \sum_{i=1}^n k_i \frac{1}{2} \rho A V_i^3 C_{pi} \quad (2)$$

$$P_z = kn \frac{1}{2} \rho A V_z^3 C_{pz} \quad (3)$$

According to (2) farm output is the sum of individual turbine outputs. Using this dependence, based on wind forecasts the distribution of wind conditions throughout the farm, i.e. the wind conditions for each windmill, should be determined taking into account the different tower heights above the ground and possibly the correction factors k_i that account for the shadowing effect dependent on the wind direction. This model requires an accurate model of wind over the farm or the farm's long-term monitoring, which will allow for selecting the coefficients. Application, for determining farm output, of formula (3), where V_z and C_{pz} are, respectively, equivalent wind speed and power coefficient for the entire farm, requires determination of these values. The equivalent of formula (3) is the characteristic of farm output power as a function of wind speed.

Output decrement of a turbine operating in the shade of another turbine or other object (forest, hills, buildings) may reach tens of percent. The impact of shadowing effect on farm output depends on the farm topology. For a large farm with compact, matrix topology the farm output decrement may occur, but to a small extent dependent on the wind direction, whereas in the case of a farm with linear topology the wind direction impact can be significant, and the analytical model should take this into account. It boils down to the dependency of correction factors k and k_j on the wind direction.

If elevations of the nacelles of individual windmills differ, then the windmills are propelled with different winds. Wind variability with elevation can be known, either from the measurement campaign before setting the farm or from analytical dependencies between wind speed and elevation above the ground, so called terrain roughness [2].

This seemingly simple analytical model requires farm monitoring and experience of the output forecasting or model developing operator. This data is available only after the farm's construction.

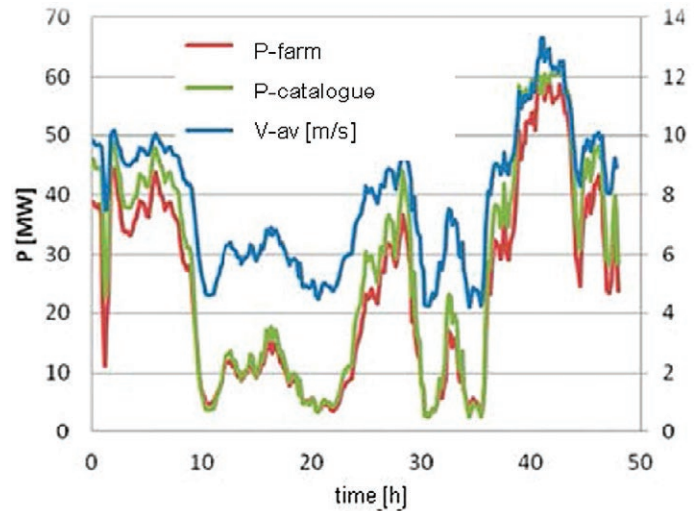


Fig. 3. Average wind speed V_{av} , output power P_{farm} wind farm and power calculated on the basis of catalogue characteristics $P_{catalogue}$

It is therefore expected that the model's accuracy will increase as time goes by. Also the forecast will be more accurate for a large farm than for a small farm. The following values are needed for forecasting: wind speed and, possibly, wind direction, air density, turbine catalogue characteristics, farm-specific correction coefficients.

Fig. 3 shows farm output calculation results based on turbine catalogue characteristics, with no correction coefficients considered and equivalent wind equal to all nacelles average. A measure of the model accuracy can be the relative difference between the farm's actual daily energy output and that calculated from the model. Since no object-specific knowledge was used to build the model, its accuracy (here the error is 13.5%) is not sufficient. This means that even with an accurate wind forecast, the output power forecast is fraught with considerable error.

Statistical model of wind farm power

It follows from the above discussion that accurate output forecasting based on analytical dependencies is a difficult task because of farm-specific characteristics' high impact and non-analytic nature. One way to take into account the specific characteristics in the model is the introduction of correction coefficients resulting from operator experience and analysis of historical data. Another way is to build a model based solely on this data. Such a model is a statistical model. With a large enough set of measurement data the farm output most likely in given circumstances, i.e. air density, and wind direction and speed, can be determined. A model so built should include the farm's non-analytic, specific features.

In order to verify the effectiveness of this method, a model was developed based on two weeks' worth of data. The data included average wind speed and farm output only. No wind direction details were used due to the short measurement period of and insufficient amount of data. The farm output powers were sorted and assigned to wind speeds with 0.5 m/s resolution. In each

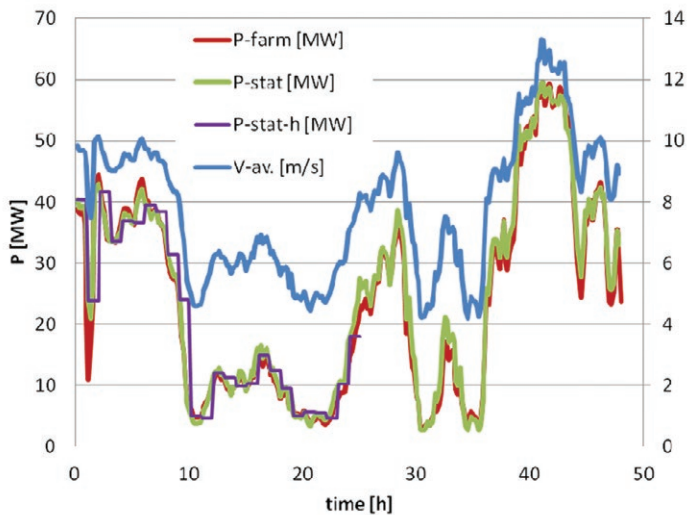


Fig. 4. Average wind speeds V_{av} , farm outputs P_{farm} wind farm, and farm outputs calculated on the basis of simplified statistical model P_{stat} for wind averaged over 10 minutes and one hour P_{stat-h}

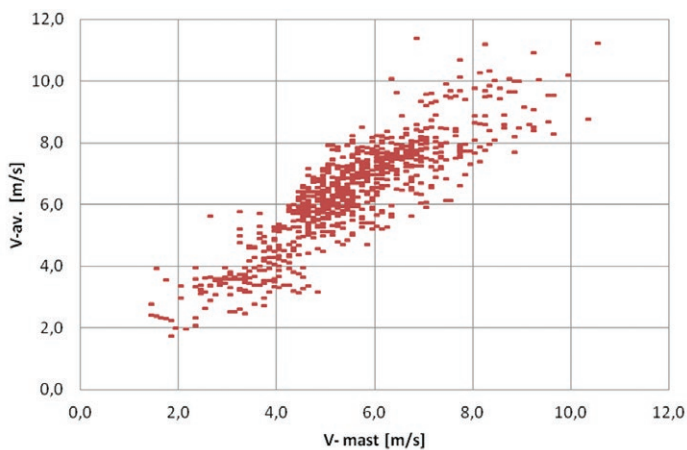


Fig. 5. Relationship between average wind at nacelle and wind at measurement mast; correlation coefficient is 0.87

subset the expected value (median or internal average of e.g. 50% of the data) was determined. In this way, the farm's output power characteristic was charted, where to each average wind speed the expected output was assigned. The characteristic was used to calculate the farm outputs for the wind waveform as shown in Fig. 3. Data from this period was not included in the analysis. The results are shown in Fig. 4. Despite the short measuring period the farm's characteristic could be developed because the wind speed varied in a wide range (Fig. 2a). The model error in this case was 3%, so the model is much more effective than the simple analytical model. One reason for the high accuracy is little variation of the wind direction. Calculations were made for wind determined every 10 minutes. In real conditions, wind is forecast with much lower resolution. The model accuracy obtained at hourly wind resolution (P_{stat-h}) is not much smaller and the error was 3.5%.

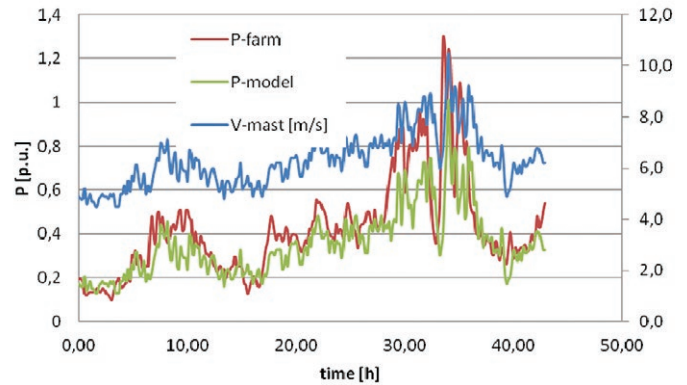


Fig. 6. Wind farm output P_{farm} , output P_{model} from model based on wind at measurement mast V_{mast}

In the model shown above the wind on the wind farm was adopted as the average wind speed measured at nacelles, and the relatively high quality of the statistical model was due to the small variation of conditions on the farm during the measurement period and the precise operation of each turbine's control system. The wind forecast for the wind farm site is not the average wind adopted in the model described above. Fig. 5 shows the average wind (based on week-long measurements) on the farm as a function of the wind measured on the farm, on a mast at an elevation 50 m above the ground, placed in an undisturbed air stream. Considering the wind speed measured of the mast as accurate wind forecast, a simple statistical model was built in the manner described above. The wind was not extrapolated to the actual nacelle height (approx. 80 m above the ground), but in the statistical model it is not necessary.

The model was developed on the basis of five day observations. The result is the farm's output expected at a specified wind speed (at measurement mast). The result is shown in Fig. 6. The difference between the actual energy output and its estimate during the observation period was 5.5%, while during the test (Fig. 6) the difference was 16%. There are several reasons for the difference. The short measurement period and small amount of data were insufficient for statistically valid results. The model development input data should represent all speed ranges in large enough numbers. In this case, in the period covered by the analysis weak winds predominated, while the winds in the test period were predominantly strong. The model takes into account only one variable – wind speed, of its direction. In a short measurement period the air density may be neglected if the temperature changes are moderate.

In the Polish climate with four seasons statistical models may be built based on data from, for instance, the preceding month.

Neural model of wind farm

As follows from previous analyses, wind farm output power is not an unambiguous and constant in time function of wind speed, despite good performance of each turbine's control system. It is appropriate to build an adaptive model, which would take into

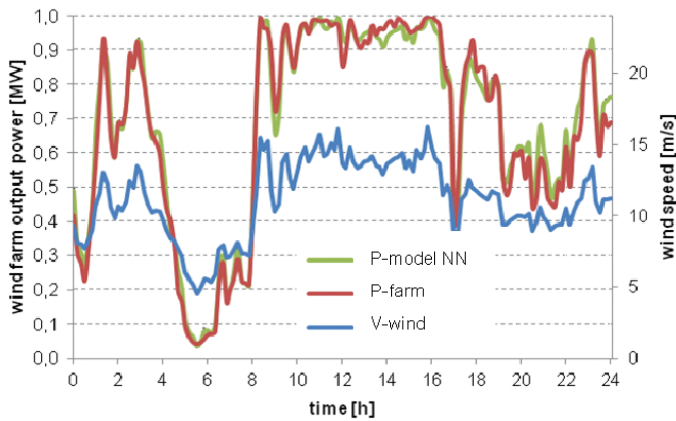
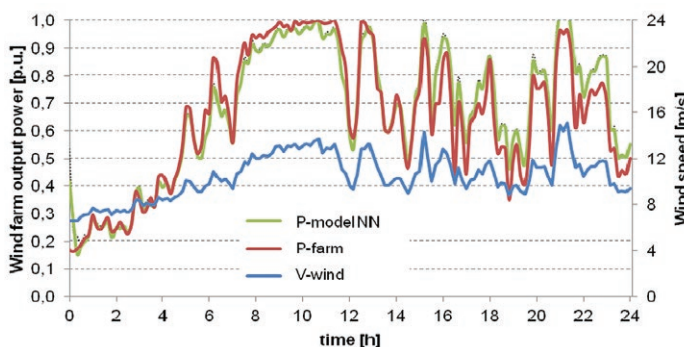


Fig. 7. Learning results of one-input neural network after eight days; power in relative units

account farm specific characteristics. Such a model is a neural network, which can approximate a farm's characteristics well, taking into account its individual features and variability. The network size and structure must be chosen adequately to the amount of training data, and in the case of a recursive network also to their course. As a result of the learning process an neural network approximates well the object for the scope and nature of the data that were adequately represented in the training data. The study examined [3, 7]: unidirectional networks, recursive networks with a large number of neurons in the hidden layer, with a small number of neurons, trained on a large set of input data and a relatively small set, various training methods were tested. Fig. 7 and 8 show an example result of neural network training and testing. This was an Elman recursive network with 15 neurons in the hidden layer, with one input (wind speed), trained by the Levenberg-Marquardt method on one-month's worth of data. Adopted as wind speed was.

As learning progresses, the network maps the farm output better and better. After one day of learning the error was approx. 30%, and after eight days only approx. 1% (Fig. 7). It can be therefore concluded that in this case the network had learned the test object very well. An example network testing process is shown in Fig. 8. The model error amounted to approx. 3% in Fig. 8a and



4.5% in Fig. 8b. The values mapped in the model are consistent with the learning results (Fig. 7). Larger differences between the model and the object are for winds faster than 12 m/s. The differences may result from: particular farm operation case (wind direction, temperature), case not covered by the learning process, under-representation of higher wind speed in the training data set, or network dynamics.

In wind speed range 11–14 [m/s] the farm characteristic is strongly non-linear and the model accuracy depends on the non-linearity's representation quality. The study shows that the average neural model error of is in the range of 3–4%. Attempts to include wind direction in the model neural did not bring the expected results. It is more appropriate to chart power curves for various wind directions in the statistical model.

As shown in [3], a neural model trained on data from even several days can be developed if the network is composed of a few neurons in the hidden layer [3, 5]. Such a network represents a wind farm's local features, but it can generate large errors when weather conditions, such as wind direction, rapidly change.

Conclusions

The study shows that with measurement data from a wind farm (average wind, power) its model can be developed with sufficient accuracy, i.e. the farm output power can be modelled based on the average wind speed for the whole farm. Application of the models requires, however, adequately numerous and well-conditioned set of input data. In the case of an analytical model a certain "manual" intervention in the model (selection of correction coefficients) is also possible. Such intervention in a statistical model is difficult, and in a neural model with a large number of weighting factors - impossible. It is much harder to build a predictive model, i.e. to estimate the farm output based on wind forecasts, as shown in Fig. 5 and 6. Even if the wind forecast is accurate, the representative (average) wind for the farm it is not known. Therefore statistical and neural models are preferred. It should be borne in mind that the problems of building an accurate power model coincide with weather forecast inaccuracy. No wind farm power model can forecast the farm's output power with a certain level of uncertainty. Farm output forecasting requires supporting tools and cumulated over time experience of the operator.

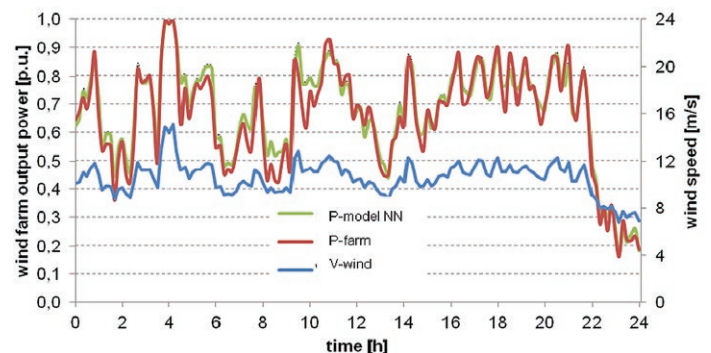


Fig. 8. Results of neural network testing on data from two consecutive days

REFERENCES

1. Standard EN 61400-12-1:2006, Wind Turbines, part 12.1: Power performance measurements of electricity producing wind turbines.
 2. Petersen E.L. et al., Wind Power Meteorology, publication of Risø National Laboratory, Roskilde, Denmark 1997.
 3. Durajczyk M., Kołakowski R., Model neuronowy mocy farmy wiatrowej na potrzeby prognozowania mocy [Neural model of wind farm power for the purpose of output forecasting], MSc thesis, Faculty of Electrical and Control Engineering, Gdańsk University of Technology, 2013.
 4. Giebel G. et al., The state of the art in short term prediction of wind power, Anemos-plus project report, 2011 [online], www.windpower-predictions.com.
 5. Madsen H., Nielsen H., Nielsen T.S., A tool for predicting the wind power production of off-shore wind plants [online], www.enfor.dk.
 6. Wang X., Guo P., Huang X., A review of wind power forecasting models, The Proc. of Int. Conf. on Smart Grid and Clean Energy Technologies, *Ener. Proc.* 2011, Vol. 12, pp. 770-778.
 7. Bogalecka E., Rubanowicz T., Neuronowy model mocy farmy wiatrowej [Neural model of wind farm power], *Mechanik* 2010, No. 7, pp. 579–586.
-

Elżbieta Bogalecka

Gdańsk University of Technology

e-mail: elzbieta.bogalecka@pg.gda.pl

Graduated from the Faculty of Electrical and Control Engineering at Gdańsk University of Technology (1976). She acquired her doctorate and habilitation at her alma mater (1987, 1998). Her research interests include automation of electric drive, especially wind power plant control algorithms, including sensorless control and renewable energy. Author of several dozen studies in this field.

Tomasz Rubanowicz

ENERGA-OBRÓT SA

e-mail: tomasz.rubanowicz@energa.pl

Graduated in Mechatronics from WAT Military University of Technology in Warsaw (2006). PhD student at the Faculty of Electrical and Control Engineering at Gdańsk University of Technology. While still a student, he began working at ELEKTROWNIE WIATROWE SA. Currently employed at ENERGA-OBRÓT SA, where his professional tasks include prediction of wind power generation capacity. Author of several publications.

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 4-9. When referring to the article please refer to the original text.

PL

Skuteczne prognozowanie krótkoterminowe mocy farm wiatrowych

Autorzy

Elżbieta Bogalecka
Tomasz Rubanowicz

Słowa kluczowe

farma wiatrowa, moc, model, predykcja

Streszczenie

Prognozowanie mocy wytwórczej konkretnej farmy wiatrowej (FW) w horyzoncie 24-godzinnym wymaga zarówno wiarygodnej prognozy wietrzności, jak i narzędzi wspomagających. Narzędzie to jest dedykowanym modelem mocy farmy. Model powinien uwzględniać nie tylko ogólne zasady przetwarzania energii wiatru na energię mechaniczną, ale także cechy szczególne konkretnej farmy. Liczba czynników wpływających na moc farmy jest duża i dokładna prognoza mocy, nawet przy dokładnej prognozie pogody, jest obciążona błędem. W artykule pokazano modele mocy farmy wiatrowej: analityczny, statystyczny i neuronowy. Badania prowadzone są na danych z rzeczywistych farm wiatrowych. Najwięcej uwagi poświęcono modelom neuronowym, sugerując się zdolnością sieci neuronowej do odtworzenia cech osobniczych konkretnej farmy. Celem badań jest odpowiedź na zadane w tytule pytanie: czy i w jakim zakresie możliwa jest dokładna krótkoterminowa prognoza mocy farmy wiatrowej?

Wstęp

Wykonanie prognozy mocy farmy wiatrowej wymaga: prognozy pogody (głównie wietrzności) i odpowiednich narzędzi wspomagających wykonanie tej prognozy. Narzędziem tym jest dedykowany model mocy farmy wiatrowej. Wykorzystując ogólnie znane zasady przetwarzania energii wiatru na energię mechaniczną i elektryczną, można otrzymać estymatę mocy pojedynczej elektrowni i całej farmy. Jednym ze źródeł błędów oceny mocy jest nieuwzględnienie cech osobniczych konkretnej farmy. Cechy te wynikają z m.in.: miejsca posadowienia, topologii terenu, rozległości i topologii farmy, czy rodzaju elektrowni i sposobu ich sterowania. Liczba czynników wpływających na moc jest tak duża, że dokładna prognoza mocy, nawet przy dokładnej prognozie pogody, jest trudna i obciążona błędem. Jednym z istotnych czynników zmniejszających błąd jest doświadczenie operatora.

Literatura tematu jest obszerna i opisywanych jest wiele metod prognozowania mocy [3, 6, 7]. Ponadto na rynku funkcjonuje kilka dedykowanych narzędzi programowych [4, 5].

Modele mocy FW można podzielić na modele: analityczne – oparte na fizykalnych zasadach przetwarzania energii wiatru na energię elektryczną, behawioralne – oparte na metodach sztucznej inteligencji (np.: sztuczne sieci neuronowe) i statystyczne. Każdy z tych modeli ma inną konstrukcję, dokładność, złożoność obliczeniową i zakres stosowania.

Celem artykułu jest przedstawienie podstawowych metod prognozowania i ocena ich dokładności. Weryfikację przeprowadzono na danych z rzeczywistych farm wiatrowych znajdujących się w północnej Polsce.

W dalszej części opisano kolejno: podstawy działania elektrowni wiatrowej i czynniki wpływające na jej moc, modele: fizykalny, statystyczny i neuronowy, weryfikację modeli oraz ich ocenę.

Elektrownia i farma wiatrowa

Głównym zadaniem elektrowni wiatrowej jest produkcja energii elektrycznej. Współczesne duże elektrownie wiatrowe są wyposażone w złożone układy sterowania, zapewniające przetwarzanie energii wiatru na energię mechaniczną z maksymalną sprawnością. Możliwe jest to dzięki przyłączeniu generatora do sieci elektroenergetycznej poprzez przekształtnik energoelektroniczny oraz dzięki zastosowaniu łopatek o zmiennym kącie ustawienia (z ang. *pitch control*). Moc elektrowni wiatrowej jest opisana zależnością:

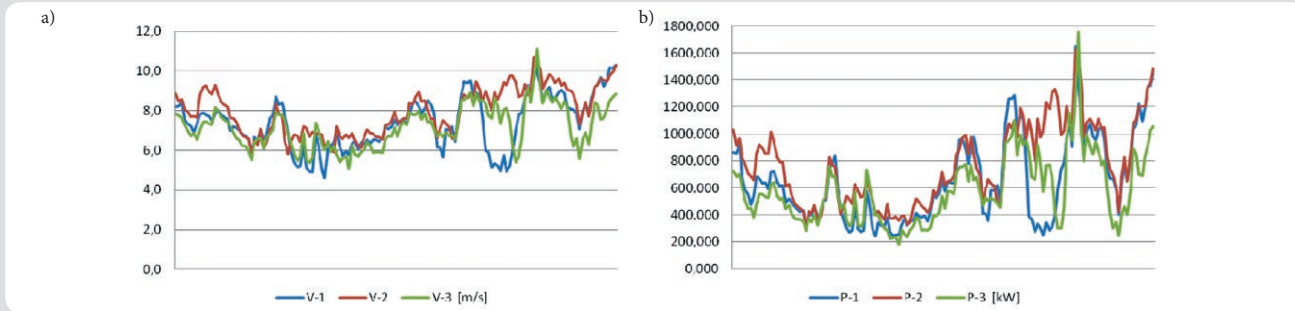
$$P = \frac{1}{2} \rho A V^3 C_p \quad (1)$$

gdzie:

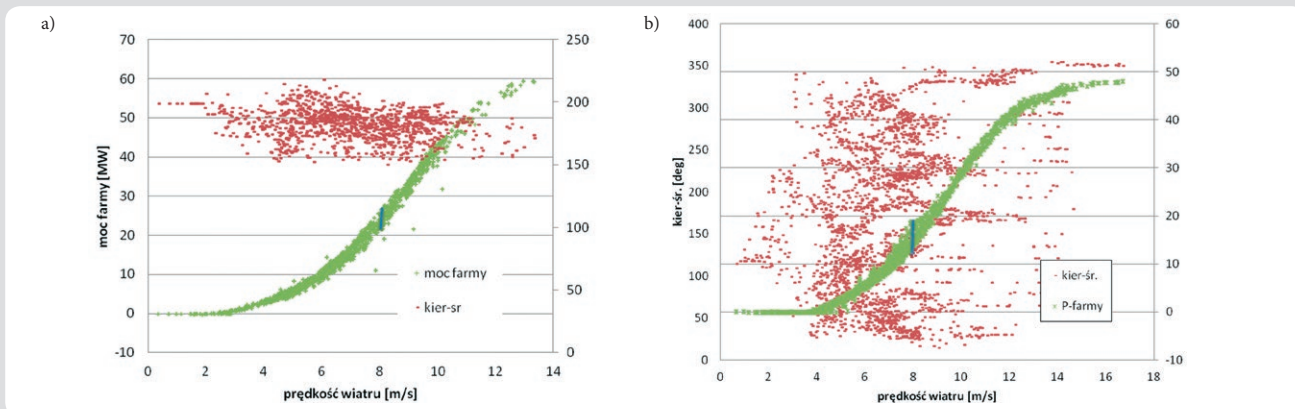
V – prędkość wiatru, A – powierzchnia omiata na przez łopaty elektrowni, ρ – gęstość powietrza, C_p – współczynnik mocy. Współczynnik mocy C_p określa sprawność przetwarzania energii zawartej w strumieniu powietrza na energię mechaniczną i zależy od konstrukcji łopatek oraz od sposobu sterowania elektrownią (kąta ustawienia łopatek, prędkości obrotowej silnika wiatrowego). Utrzymanie współczynnika mocy na wartości maksymalnej wymaga pracy silnika wiatrowego ze zmienną prędkością obrotową, zależną od prędkości wiatru. Większość współczesnych dużych elektrowni pracuje ze zmienną prędkością obrotową dzięki przekształtnikowi, którym jest przeważnie falownik napięcia. Przy prędkościach wiatru mniejszych niż prędkość znamionowa generator i silnik wiatrowy mają prędkość obrotową zapewniającą maksymalną sprawność. Przy większych prędkościach wiatru moc generatora elektrowni jest ograniczona do wartości znamionowej, a układ sterowania kątem ustawienia łopatek powoduje zmniejszenie siły nośnej, tak aby prędkość obrotowa silnika wiatrowego była utrzymywana na prawie stałej wartości. Elektrownia pracuje więc ze zmiennym

współczynnikiem mocy C_p , maksymalnym w zakresie pracy optymalnej ($V < V_n$) i malejącym w zakresie ograniczania mocy ($V > V_n$). Podstawową wielkością, względem której ustalane są (w układzie regulacji) kąty ustawienia łopatek i moc elektrowni, jest nie prędkość wiatru, a prędkość kątowna generatora. Zamieszczone w katalogach charakterystyki mocy w funkcji prędkości wiatru nie są charakterystykami naturalnymi elektrowni wiatrowej, a wynikają ze sposobu sterowania elektrownią. Publikowane charakterystyki są uzyskiwane na podstawie pomiarów, po sprowadzeniu do standardowych warunków [1]. Charakterystyka rzeczywista jest obciążona niepewnością. Odchylenie mocy elektrowni rzeczywistej od wartości katalogowej wynika z np. innej temperatury i ciśnienia, czyli gęstości powietrza, czy dynamiki wiatru.

Na farmie wiatrowej znajduje się od kilku do kilkudziesięciu elektrowni, przeważnie jednego rodzaju, położonych na rozległym terenie. Każda elektrownia pracuje w trochę innych warunkach wiatrowych, a więc w innym punkcie pracy na charakterystyce. Warunki te są określone przez: lokalne warunki wiatrowe, czyli prędkość i kierunek wiatru, wysokość gondoli n.p.g., miejsce na farmie oraz przesłonięcie wynikające z położenia względem innych elektrowni i względem kierunku wiatru. Różnice te mogą być dosyć duże. Na rys. 1 pokazano uzyskane w warunkach naturalnych przykładowe przebiegi prędkości wiatru oraz moce dla trzech wybranych elektrowni na rozległej farmie wiatrowej. Czujniki prędkości wiatru są umieszczone na gondolach za silnikiem wiatrowym, nie mierzą więc prędkości wiatru napływającego. To wyjaśnia, m.in. dlaczego prędkość wirnika jest bardziej wiarygodną wielkością wejściową dla układu sterowania niż prędkość wiatru. Moc farmy jest sumą mocy poszczególnych elektrowni. Na rys. 2 pokazano zbiór punktów pracy farmy wiatrowej (z rys. 1), czyli moc farmy w funkcji średniej prędkości



Rys. 1. Prędkości wiatru i moce elektrowni wiatrowych na rozległej farmie wiatrowej (za okres jednej doby)



Rys. 2. Moc FW i średni kierunek wiatru w funkcji średniej prędkości wiatru, a) farmy wiatrowej o mocy ok. 60 MW z okresu jednego tygodnia, b) farmy wiatrowej o mocy ok. 50 MW za okres trzech tygodni

wiatru, otrzymany na podstawie wartości średnich 10-minutowych, z okresu jednego tygodnia. Średnia prędkość wiatru to średnia arytmetyczna prędkości wiatru ze wszystkich czujników na gondolach. Z rys. 2a wynika, że pomimo odmiennych warunków pracy każdej elektrowni (rys. 1) moc farmy obciążona jest niewielką niepewnością (tu maks. ok. 8%), co oznacza, że układy regulacji każdej elektrowni pracują precyzyjnie oraz że w okresie pomiarowym panowały podobne warunki (gęstość powietrza, zmienność kierunku wiatru). Jeżeli zmienność kierunku wiatru jest duża (rys. 2b), to większa jest też niepewność mocy farmy (tu maks. 14,5%). Sposzczenia te są istotne dla prognozowania mocy farmy wiatrowej.

Model fizyczny mocy farmy wiatrowej

Gdyby założyć, że charakterystyka mocy farmy w funkcji prędkości wiatru jest przeskalowaną charakterystyką pojedynczej elektrowni, to można zbudować prosty model mocy farmy wiatrowej. Na podstawie równania (1) i katalogowej charakterystyki zainstalowanych na farmie elektrowni wiatrowych można obliczyć moc pojedynczego wiatraka dla określonej prędkości wiatru. W przypadku farmy wiatrowej jej moc nie jest jednak tylko wielokrotnością mocy pojedynczej elektrowni. Pomijając różne warunki wiatrowe, należy uwzględnić w obliczeniach pewne cechy osobnicze farmy, np.: zmniejszenie mocy na skutek przesłonięcia czy posadowienie gondoli na różnych wysokościach. Każda farma ma swoje cechy indywidualne, które nie poddają się algorytmizacji w prosty sposób. W modelu mocy FW należy uwzględnić

wymienione powyżej czynniki: wysokość n.p.g., przesłonięcie, zmienność wiatru na terenie farmy. Moc farmy można określić analitycznie, korzystając z zależności (2) albo (3):

$$P_z = \sum_{i=1}^n P_i = \sum_{i=1}^n k_i \frac{1}{2} \rho A V_i^3 C_{pi} \quad (2)$$

$$P_z = k n \frac{1}{2} \rho A V_z^3 C_{pz} \quad (3)$$

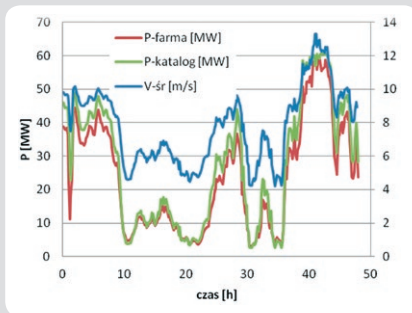
Zgodnie z (2) moc farmy jest sumą mocy poszczególnych elektrowni. Korzystając z tej zależności, należy na podstawie prognozy wiatru określić rozkład wiatru na farmie, czyli warunki wiatrowe dla każdego wiatraka, uwzględniając różne wysokości wież n.p.g. i ewentualnie współczynniki korekcyjne k_i uwzględniające przesłonięcie zależne od kierunku wiatru. Model taki wymaga dokładnego modelu wiatru na farmie albo długotrwałych obserwacji farmy, które pozwolą dobrać współczynniki. Zastosowanie, w celu określenia mocy farmy wzoru (3), gdzie V_z i C_{pz} są odpowiednio zastępczymi wiatrem i współczynnikiem mocy dla całej farmy, wymaga określenia tych wielkości. Odpowiednikiem wzoru (3) jest charakterystyka mocy farmy w funkcji prędkości wiatru.

Spadek mocy elektrowni pracującej w cieniu innej elektrowni lub innego obiektu (las, wzgórze, budynek) może sięgać kilkadziesiąt procent. Wpływ przesłonięcia na moc farmy zależy od jej topologii. Dla dużej farmy o zwartej, matrycowej topologii zmniejszenie mocy farmy może występować, ale w niewielkim stopniu zależy od kierunku wiatru, natomiast w przypadku

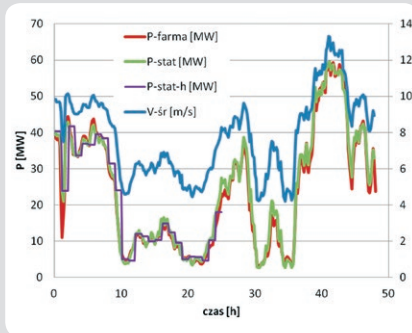
farmy o topologii liniowej wpływ kierunku wiatru może być istotny i model analityczny powinien to uwzględniać. Sprowadza się to do uzależnienia współczynników korekcyjnych k i k_i od kierunku wiatru.

Jeżeli gondole poszczególnych wiatraków leżą na różnych wysokościach, to pracują one na różnym wietrze. Zmienność wiatru z wysokością może być znana, albo z kampanii pomiarowej przed posadowieniem farmy, albo z zależności analitycznych uzależniających prędkość wiatru od wysokości n.p.g. oraz tzw. szorstkości terenu [2]. Pozornie prosty model analityczny wymaga obserwacji farmy i doświadczenia operatora przygotowującego prognozę mocy czy budującego model. Dane te są dostępne dopiero po wybudowaniu farmy. Należy więc oczekiwać, że model będzie w miarę wpływu czasu dokładniejszy. Dokładniejsza będzie także prognoza dla farmy dużej niż małej. Do sporządzenia prognozy potrzebne są: prędkość i ewentualnie kierunek wiatru, gęstość powietrza, charakterystyki katalogowe elektrowni wiatrowych i współczynniki korekcyjne definiujące konkretną farmę. Na rys. 3 pokazano wynik obliczenia mocy farmy na podstawie katalogowej charakterystyki zastosowanych elektrowni wiatrowych, gdy nie uwzględniono żadnych współczynników korekcyjnych, a za wiatr zastępczy przyjęto średnią prędkość wiatru ze wszystkich gondoli. Miarą dokładności modelu może być względna wartość różnicy energii wyprodukowanej przez farmę w ciągu doby i energii obliczonej z modelu. Ponieważ przy konstrukcji modelu nie wykorzystano żadnej wiedzy o obiekcie, to dokładność (tu błąd wynosi 13,5%) nie jest wystarczająca.

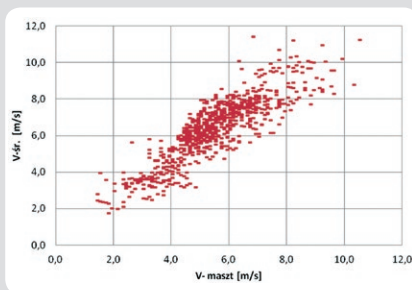
Oznacza to, że nawet przy dokładnej prognozie wiatru prognoza mocy jest obciążona sporym błędem.



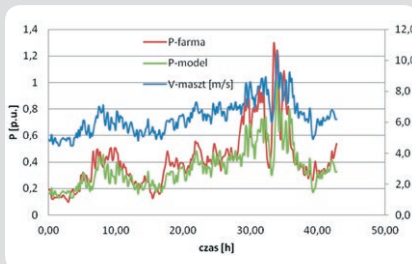
Rys. 3. Przebieg prędkości średniej wiatru V-śr, mocy farmy P-farma oraz mocy obliczonej na podstawie charakterystyk katalogowych P-katalog



Rys. 4. Przebieg prędkości średniej wiatru V-śr, mocy farmy P-farma oraz mocy obliczonych na podstawie uproszczonego modelu statystycznego P-stat dla wiatru uśrednionego za 10 min oraz za godzinę P-stat-h



Rys. 5. Zależność pomiędzy wiatrem średnim z gondoli a wiatrem z masztu pomiarowego; współczynnik korelacji wynosi 0,87



Rys. 6. Moc farmy wiatrowej P-farma, moc z modelu P-model opartego na wietrze z masztu pomiarowego V-maszt

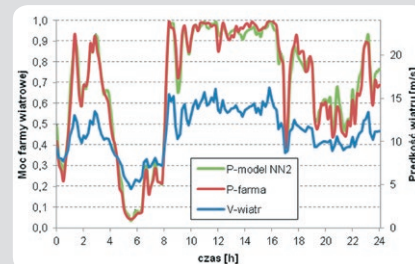
Model statystyczny mocy farmy wiatrowej
Z rozważań przedstawionych powyżej wynika, że dokładna prognoza mocy na podstawie zależności analitycznych jest zadaniem trudnym, ponieważ cechy osobnicze farmy mają duży wpływ i są nieanalityczne. Jednym ze sposobów na uwzględnienie w modelu tych cech szczególnych danej farmy wiatrowej jest wprowadzenie współczynników korekcyjnych będących wynikiem doświadczenia operatora i analizy danych historycznych. Drugim sposobem jest zbudowanie modelu opartego wyłącznie na tych danych. Modelem takim jest model statystyczny. Dysponując odpowiednio dużym zbiorem danych pomiarowych, można znaleźć najbardziej prawdopodobną moc farmy w danych warunkach określonych przez gęstość powietrza, kierunek i prędkość wiatru. Tak skonstruowany model powinien zawrzeć nieanalityczne cechy osobnicze farmy.

Dla sprawdzenia skuteczności tej metody zbudowano model na podstawie danych za okres dwóch tygodni. Wykorzystano tylko dane o średniej prędkości wiatru i mocy farmy. Nie wykorzystano informacji o kierunku wiatru ze względu na krótki okres pomiarowy i niewystarczającą liczbę danych. Dane o mocy farmy zostały posortowane i przyporządkowane do prędkości wiatru z rozdzielczością 0,5 m/s. W każdym podzbiorek została określona wartość oczekiwana (mediana lub średnia wewnętrzna z np. 50% danych). W ten sposób powstała charakterystyka mocy farmy, gdzie każdej prędkości średniej wiatru przypisano wartość oczekiwaną mocy. Charakterystykę tę wykorzystano do obliczenia mocy farmy dla przebiegu wiatru jak na rys. 3. Dane z tego okresu nie były uwzględniane w analizie. Wyniki przedstawiono na rys. 4. Pomimo krótkiego okresu pomiarowego można było odtworzyć charakterystykę farmy, ponieważ prędkość wiatru zmieniała się w szerokim zakresie (rys. 2a). Błąd modelu w tym przypadku wyniósł 3%, a więc model ten jest o wiele bardziej skuteczny niż prosty model analityczny. Jedną z przyczyn dużej dokładności jest niewielka zmienność kierunku wiatru. Obliczenia wykonano dla wiatru określanego co 10 min. W rzeczywistości prognoza wiatru ma dużo mniejszą rozdzielczość. Uzyskana dokładność modelu przy godzinnej rozdzielczości wiatru (P-stat-h) jest niewiele mniejsza i błąd wyniósł 3,5%.

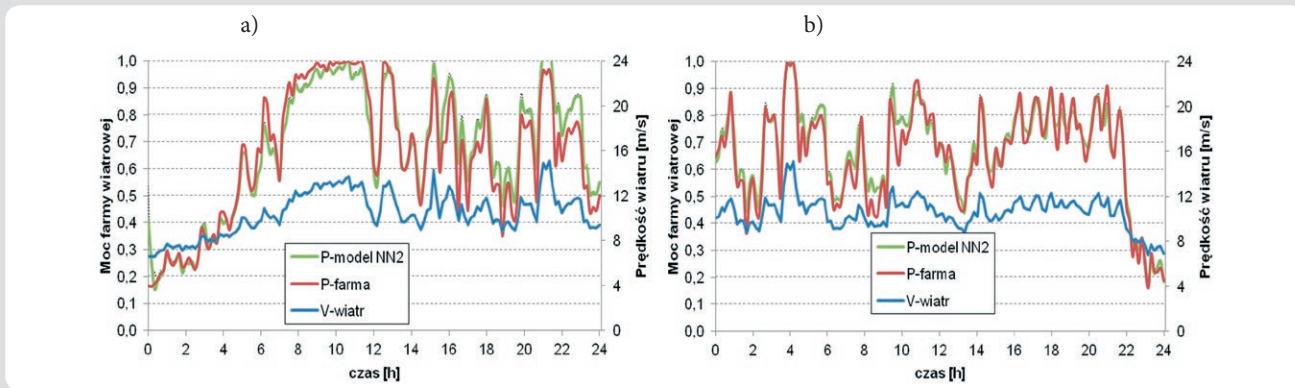
W pokazanych powyżej modelach za wiatr na farmie wiatrowej przyjęto średnią

prędkość wiatru zmierzoną na gondolach, a względnie wysoka jakość modelu statystycznego wynika z niewielkiej zmienności warunków na farmie w okresie pomiarowym oraz z precyzyjnego działania układów sterowania każdą elektrownią. Wiatr prognozowany dla terenu farmy wiatrowej nie jest przyjmowanym, w opisanym wyżej modelu, wiatrem średnim. Na rys. 5 pokazano (uzyskane z pomiarów w okresie tygodnia) wartość wiatru średniego dla farmy w funkcji wiatru mierzonego na farmie, na maszcie o wysokości 50 m n.p.g., umieszczonym w niezaburzonym strumieniu powietrza. Traktując wartość prędkości wiatru z masztu jako dokładną prognozę wiatru, zbudowano w sposób opisany powyżej prosty model statystyczny. Nie wykonano ekstrapolacji wiatru do wysokości gondoli (ok. 80 m n.p.g.), ale w modelu statystycznym nie jest to konieczne. Model zbudowano na podstawie obserwacji przez pięć dni. W wyniku otrzymuje się oczekiwaną wartość mocy farmy wiatrowej dla określonej prędkości wiatru (z masztu pomiarowego). Wynik pokazano na rys. 6. Różnica pomiędzy energią wyprodukowaną a jej estymatą w okresie obserwacji wyniosła 5,5%, natomiast w okresie testowania (rys. 6) różnica ta wyniosła 16%. Przyczyną rozbieżności jest kilka. Krótki okres pomiarowy i mała ilość danych nie dają wyników statystycznie poprawnych. W danych przyjętych do budowy modelu wszystkie zakresy prędkości powinny być wystarczająco licznie reprezentowane. W tym przypadku w okresie przyjętym do analizy dominowały wiatry słabe, podczas gdy w okresie testowym silniejsze. Model uwzględniał tylko jedną zmienną – prędkość wiatru, pomijając jego kierunek. W krótkim okresie pomiarowym można pominąć gęstość powietrza, o ile zmiany temperatury nie są duże. W klimacie Polski, gdzie występują cztery pory roku, można modele statystyczne budować na podstawie danych z np.: miesiąca poprzedzającego.

Model neuronowy farmy wiatrowej
Jak wynika z analiz przeprowadzonych wcześniej, moc farmy wiatrowej nie jest jednoznaczna, niezmienna w czasie funkcją prędkości wiatru, pomimo dokładnie działających układów regulacji każdej elektrowni. Właściwe jest zbudowanie modelu adaptacyjnego, który uwzględniałby cechy osobnicze farmy. Modelem takim jest sieć neuronowa, która może być dobrym aproksymatorem charakterystyk farmy wiatrowej, uwzględniającym jej cechy indywidualne i zmienność. Należy odpowiednio dobrać wielkość i strukturę sieci do ilości danych uczących, a w przypadku sieci rekurencyjnej także do ich przebiegu. W wyniku procesu uczenia sieć neuronowa dobrze aproksymuje obiekt dla zakresu i charakteru danych, które były w danych uczących odpowiednio reprezentowane. W ramach badań sprawdzono [3, 7]: sieci jednokierunkowe, sieci rekurencyjne, o dużej liczbie neuronów w warstwie ukrytej, o małej liczbie neuronów, uczone na dużym zbiorze danych wejściowych i na stosunkowo małym zbiorze, sprawdzono różne metody uczenia. Na rys. 7 i 8 pokazano przykładowy wynik uczenia i testowania sieci neuronowej. Zastosowano sieć rekurencyjną Elmana z 15 neuronami w warstwie ukrytej, z jednym wejściem



Rys. 7. Wyniki uczenia sieci neuronowej z jednym wejściem po ośmiu dniach; moc w jednostkach względnych



Rys. 8. Wyniki testowania sieci neuronowej na danych z dwóch kolejnych dni

(prędkością wiatru), uczoną metodą Levenberga-Marquardta na danych z okresu miesiąca. Za prędkość wiatru przyjęto średnią arytmetyczną prędkości wiatru ze wszystkich siłowni wiatrowych.

W trakcie uczenia sieć coraz lepiej odtwarza moc farmy wiatrowej. Po jednym dniu uczenia błąd wynosił ok. 30%, a po ośmiu dniach już tylko ok. 1% (rys. 7). Można więc stwierdzić, że w powyższym przypadku sieć bardzo dobrze nauczyła się badanego obiektu. Przykładowy proces testowania sieci pokazano na rys. 8. Błąd modelu wyniósł ok. 3% na rys. 8a i 4,5% na rys. 8b. Wartości odtworzone w modelu są zgodne z wynikami uczenia (rys. 7). Większe różnice między modelem a obiektem występują dla wiatrów większych, powyżej 12 m/s. Różnice mogą wynikać ze: szczególnego przypadku działania farmy (kierunku wiatru, temperatury), przypadku nieobjętego procesem uczenia, niedostateczną reprezentacją większych prędkości wiatru w ciągu uczącym, dynamiką sieci. W zakresie prędkości wiatru 11–14 [m/s] charakterystyka farmy jest silnie nieliniowa i dla dokładności modelu ważna jest jakość odtworzenia tej nieliniowości. Z badań wynika, że średni błąd modelu neuronowego mieści się w granicach 3–4%. Próby wprowadzenia do modelu neuronowego kierunku wiatru nie przyniosły spodziewanych rezultatów. Bardziej właściwie jest wyznaczenie krzywych mocy dla różnych kierunków wiatru w modelu statystycznym.

Jak pokazano w [3], możliwe jest zbudowanie modelu neuronowego uczonego

na danych z okresu nawet kilku dni, o ile sieć jest złożona z niewielu neuronów w warstwie ukrytej [3, 5]. Taka sieć odtwarza właściwości lokalne farmy wiatrowej, ale może generować duże błędy, gdy nastąpi gwałtowna zmiana warunków pogodowych, np. kierunku wiatru.

Wnioski

Z przeprowadzonych badań wynika, że dysponując danymi pomiarowymi z farmy wiatrowej (średni wiatr, moc), można zbudować jej model o dosyć dużej dokładności, czyli odtworzyć moc farmy na podstawie średniej prędkości wiatru dla całej farmy. Aplikacja modeli wymaga jednak odpowiednio licznego i dobrze uwarunkowanego zbioru danych wejściowych. W przypadku modelu analitycznego możliwa jest też pewna „ręczna” ingerencja w model (dobór współczynników korekcyjnych). Ingerencja taka w model statystyczny jest utrudniona, a w neuronowy o dużej liczbie współczynników wagowych – niemożliwa. Dużo trudniej jest zbudować model prognostyczny, czyli wyznaczyć estymatę mocy farmy na podstawie prognozy wiatru, co pokazano na rys. 5 i 6. Nawet jeżeli prognoza wiatru jest dokładna, to nie jest znany reprezentatywny (średni) wiatr dla farmy. Dlatego też modelami preferowanymi są modele statystyczne lub neuronowe. Należy pamiętać, że na problemy zbudowania dokładnego modelu mocy nakłada się niedokładność prognozy pogody. Żaden model mocy farmy wiatrowej nie zapewni prognozy mocy farmy z określonym poziomem niepewności. Prognozowanie

mocy farmy wymaga narzędzi wspomagających i skumulowanego w czasie doświadczenia operatora.

Bibliografia

1. Norma EN 61400-12-1:2006, Wind Turbines, part 12.1: Power performance measurements of electricity producing wind turbines.
2. Petersen E.L. i in., Wind Power Meteorology, publikacja Risø National Laboratory, Roskilde, Denmark 1997.
3. Durajczyk M., Kołakowski R., Model neuronowy mocy farmy wiatrowej na potrzeby prognozowania mocy, praca dyplomowa, WEiA Politechnika Gdańska, 2013.
4. Giebel G. i in., The state of the art in short term prediction of wind power, Anemos-plus project report, 2011 [online], www.windpowerpredictions.com.
5. Madsen H., Nielsen H., Nielsen T.S., A tool for predicting the wind power production of off-shore wind plants [online], www.enfor.dk.
6. Wang X., Guo P., Huang X., A review of wind power forecasting models, The Proc. of Int. Conf. on Smart Grid and Clean Energy Technologies, *Ener. Proc.* 2011, Vol. 12, s. 770–778.
7. Bogalecka E., Rubanowicz T., Neuronowy model mocy farmy wiatrowej, *Mechanik* 2010, nr 7, s. 579–586.

Elżbieta Bogalecka

dr hab. inż.

Politechnika Gdańska

e-mail: elzbieta.bogalecka@pg.gda.pl

Absolwentka Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej (1976). Doktorat i habilitację zdobyła na swojej macierzystej uczelni (1987, 1998). Przedmiotem jej badań są: automatyka napędu elektrycznego, a szczególnie algorytmy sterowania elektrownią wiatrową, w tym sterowanie bezczujnikowe i energetyka odnawialna. Autorka kilkudziesięciu prac z tej dziedziny.

Tomasz Rubanowicz

mgr inż.

ENERGA-OBRÓT SA

e-mail: tomasz.rubanowicz@energa.pl

Absolwent Wojskowej Akademii Technicznej w Warszawie (2006), kierunek mechatronika. Doktorant na Wydziale Elektrotechniki i Automatyki Politechniki Gdańskiej. Jeszcze w trakcie studiów rozpoczął pracę w firmie Elektrownie Wiatrowe SA. Obecnie jest zatrudniony w ENERGA-OBRÓT SA, gdzie zajmuje się zawodowo m.in. predykcją mocy wytwórczej elektrowni wiatrowych. Autor kilkunastu publikacji.