

Scheduling Coordinator's Flat Rate Service for Wind Energy Development in Poland

Authors

Zbigniew Prondziński
 Tomasz Rubanowicz

Keywords

balancing market, wind power, forecasting

Abstract

The development of the electricity market has made the energy industry an attractive investment for many businesses. In recent years, the electricity market has been going through the process of liberalization, which has contributed to the provision of new services for investors interested in the development of the energy industry. Recently, one of the most rapidly growing sources of electricity has been wind farms. Few investors are aware of the consequences of connecting wind farms to the national power grid, as well as of the subsequent exploitation of these resources. After the Electricity Sales Contract has been concluded, investors agree to predict electrical capacity generation within the span of 24 hours with a daily advance. The specific nature of wind farm functioning makes the prediction of electrical capacity generation difficult and, consequently, the owners bear the costs of deviations on the electricity balancing market. The resulting costs may result in the lack of liquidity of the project owner and, ultimately, in bankruptcy. In such a case, the Scheduling Coordinator's flat rate service is a solution for the owner of a wind farm.

The paper presents an analysis of selected forecasting models used to predict the electrical capacity of wind farms, as well as the Scheduling Coordinator's service.

DOI: 10.12736/issn.2300-3022.2014213

1. Electricity market

The development of the electricity market (EM) has made the energy industry an attractive investment for many businesses. Establishing of the balancing market (BM) in 2001 was one of the steps towards liberalisation of EM. BM is the so-called technical market, which is used for current balancing of electricity demand and electricity generation in the National Power Grid (KSE). Operations on the market include the performance of contracts for purchase/sale of energy concluded by the participants and the real-time balancing of electricity demand with its production in the KSE. The existence of the BM is necessary for functioning of the energy market, and the participation of energy purchasers thereon is mandatory [1].

The BM operation is possible only thanks to the fact that the producers may quickly increase or reduce the electricity generation. For this reason the energy prices on the BM are determined on the basis of contracts concluded between OSP and energy producers. The prices of energy purchased and sold by the participants on the BM are roughly equal to the prices on the competitive market. Participation on the BM definitely means additional costs and significantly higher risk. The prices on the

BM are published with a one-day delay and may range from PLN 70 to 1500 per 1 MWh. Therefore, in both cases the transactions are unprofitable for the end customer. In order to minimise the transaction volume on the BM, the customers who purchase energy on the competitive market try to prepare the consumption forecasts as accurately as possible.

In recent years, the electricity market has been going through the process of liberalization, which has contributed to the provision of new services for investors interested in the development of the energy industry. Recently, one of the most rapidly growing sources of electricity has been wind farms (EW). Few investors are aware of the consequences of connecting wind farms to the National Power Grid, as well as of the subsequent exploitation of these resources. A wind farm connected to the grid is not only a source of revenue, but also a cost. To current Instructions for Operation and Maintenance of Transmission Network (IRiESP) governs the principles of operation for the EM. The Instructions indicate that each owner of an energy generating unit connected to the grid is required to draw up daily and hourly diagrams of facility operation. Predicting power generated in wind farms is not an easy task. Forecasts are prepared in a 24-hour horizon on

the day preceding the trading day. The daily advance results from the energy contracting requirements under contract, and the horizon depends on the trading organisation and diverse trading conditions (i.e. closing of gate on the BM). Forecasting involves foreseeing of the electricity generation volume in advance on a daily and hourly basis. The forecasts prepared for the balancing market unit of ENERGA-OBRÓT SA (EOB) include end customers (consumers) and sources of generation. The forecast of electricity demand is used to purchase electricity on the wholesale market to satisfy the consumer demand. Wind farms belong to the least predictable sources of generation in terms of operation characteristics. The nature of their operation makes the power prediction difficult; as a result the owners bear the costs for deviations on the balancing market (for the so-called imbalance). Such costs may result in the lack of liquidity of the project owner and, ultimately, in bankruptcy. In such a case, the Scheduling Coordinator's (SC) flatrate service is an optimal solution for the owner of a wind farm (WF). The service is based on expansion of collaboration between the investor (OZE) and EOB by concluding the SC agreement. By concluding the SC agreement EOB assumes the costs of wind farm participation on the BM. In return, the producer pays a flat-rate (PLN/MWh) for EOB, which depends on electricity generation in the particular billing period, as measured by the metering and billing system. With the SC agreement the producers gain a simple mechanism for planning of costs for the wind farm and for preparing business plans; in addition they reduce their own cost risk related to participation on the BM.

Planning of power generation has an impact on the safety of KSE operation and the electricity trade on the market. Due to the increasing power rating of wind farms connected to the KSE, power prediction plays an increasingly important role. According to the URE the estimated total power of the installed wind farms is to be approx. 2000 MW and 2500 MW in 2013 and 2014, respectively.

Various studies on forecast models have been continually carried out for many years. Innovative solutions will contribute to improvement of the positions of operators on the competitive market. Many different tools for the prediction of power from wind sources have been available since 2002, but they are characterised by unsatisfactory forecast error, as referred to in [1–4]. Currently, hybrid models are highly popular in forecasting [5–7]. The authors of this publication have presented three freely selected forecasting methods used, among others, in daily work, and often found in expert literature [1–9]. Application of various forecasting methods never guarantees a perfect forecast. Continuous attempts should be made to achieve the expected results by obtaining thorough knowledge and operator experience.

Particular attention should be paid to the possible use of artificial neural networks (SSN). The use of neural models enables the prediction of power generated at any wind farm, provided that the historical data related to generation in the facility is available. To meet the market expectations ENERGA-OBRÓT SA (SOB) has made it possible for contractors to account for deviations by a fixed flat-rate fee (SC), at the same assuming the costs, risk and responsibility for imbalance. A deviation means the difference between the hourly electricity planned and reported by

the producer, and the hourly electricity actually generated and introduced to the distribution grid, as measured by the metering system. The Scheduling Operator's (SC) service is a good alternative for EW owners. With the SC service the estimation of revenues and costs related to the EW functioning on the market is much easier because of the fixed fee. However, this type of option has not solved the issue of prediction and further costs for deviations.

Because EOB has both producers and consumers on its territory, it is required to estimate the amount of electricity needed for a balancing market unit. Assuming that EW (producers) generate 100 MWh of energy and bring it to the grid within a day or an hour on the wholesale market and that the (consumer) demand for energy is 1,500 MWh, EOB would have to purchase 1000 MWh of energy on the wholesale market. An accurate prediction of the power generated at wind farms reduces the costs of participation on the mandatory BM.

Short-term daily and hourly prediction of the power generated at wind farms is not an easy task due to the stochastic nature of force (wind) and the facility structure. Electricity generation does not result only from the installed power rating in a wind farm, but primarily from the instantaneous wind speed expressed in the third power. As the meteorological conditions change over the day, they cause high instability of energy generation. Because of the random value of active power, it is difficult to estimate it precisely in the long term. Obviously, the longer the estimation period is, the greater the forecast error is. Because of the dynamics of meteorological conditions, wind farms are considered to be "unsteady" sources of active power generation.

As a result of the development trend of EW (rapid rise in nominal power in KSE) the forecasting is gradually playing an increasingly important role in improvement of the energy security. Classification can be made for the purposes of power prediction in EW, for example in terms of the unit power rating (Fig. 1). Typical power plants used in the energy industry are units of low and high power rating. Low power means individual power plants (less than 850 kW) and small farms (up to 2 MW). The continuing trend in the wind energy industry is to build wind farms rather than individual plants. Farms consist of several to a dozen or so wind turbines connected to the transformer station (400/110 kV). Currently, the rated power of the largest wind farm in Poland is as high as 120 MW.

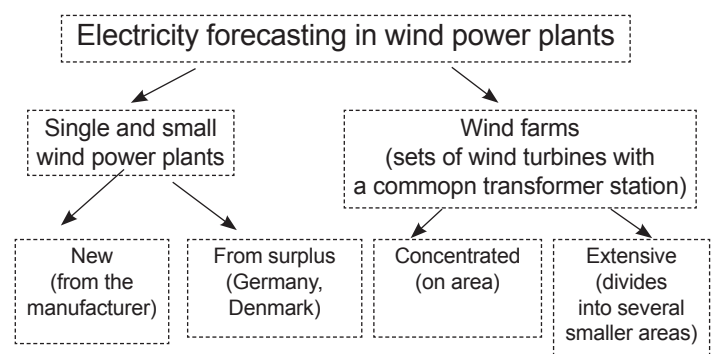


Fig. 1. Classification of wind farms for forecasting of electricity generation

Three different approaches connecting the wind forecast with the wind power output can be distinguished based on the literature [7], i.e.:

1. Physical approach – based only on the nature of conversion of the wind power into electrical power
2. Statistical approach – describes the relationship between the forecast wind parameters and the output wind power by a statistical analysis of past time series
3. “Learning” approach – uses artificial intelligence methods to obtain the relationship between wind forecast and output power in the form of a time series.

A hybrid approach is used to achieve more accurate forecasts – it combines the afore-mentioned approaches in a single model. Despite the availability of data and ready mathematical models, without the proper knowledge and experience predictions may be ineffective, sometimes costly.

The hybrid models use a variety of data, i.e. the base relationship between power and wind force, the producer’s power characteristics, information about the planned shutdowns of wind farm, and meteorological forecasts (wind force and direction, atmospheric pressure, air temperature – taking into account the season of the year). Knowledge and experience can be gained through long-term observations of wind sources.

The physical approach includes a set of models which take into account:

- the wind conditions at the examined location (change dynamics) and the height of turbine nacelle
- the effect of interaction between wind turbine masts (wake effect)
- electronic and mechanic characteristics of power station (power curve) output power statistics.

There are methods for learning and self-learning, which allow obtaining the assumed and effective operation, even when the producer does not know any algorithm that could be used to solve the task. The grid always operates as a whole and its individual elements contribute to all operations performed by the grid. One of the consequences of such grid operation is its ability to function properly even with incomplete data.

1.1. Actual characteristics

Selection of the power characteristics (producer’s curve) without the operator experience may be difficult and insufficient. The actual power characteristics do not coincide with the theory for most part of the year. One of the factors that hinder the power estimation are internal conditions (including the farm structure) and external conditions (weather), which can be seen in the form of power spread in Fig. 2. This is a result of the dynamics of changes in wind direction, nacelle location, dynamics of panels and the lack of periodic calibration of anemometers.

The power spread phenomenon usually occurs during the summer period, when the wind speed and direction change dynamically. Fig. 2 shows the power curve with power spread

for power plant operation, from 4 to 15 m/s. The points located under the theoretical power curve (marked with blue dots) are understandable. Less power for instantaneous wind speed is a result of the dynamics of changes in wind direction, the change in panel angle (high rotor inertia), the change in nacelle angle, technical limitations (e.g. high temperature of gear), as well as the device mechanical components (i.e. mechanical vibrations of panels, generator shaft, tower and other elements).




Fig. 2. Characteristics for power curves in five wind power plants in the wind speed function (measurements in the summer period, high wind variability) [1]

The cause is also the variability of air density and humidity. The power generated over the theoretical curve is caused by the dynamics of changes in wind and nacelle direction, and probably by measurement error (e.g. unregulated anemometer or lack of periodic calibration of anemometer). The power spread to the third power may also be a result of high instantaneous values of wind gusts. The instantaneous values of power and wind speed are averaged for the last 10 minutes and sent to the control system, which processes the measurement results and stores the averaged measurement data. Fig. 3 is an example, with the measurement point (smaller dots) equal to the energy value for 2 sec. Fig. 3 shows the average value of electricity for the last 10 minutes against the theoretical power curve, in the instantaneous wind speed function.

P_{sr} is the mean energy value after 10 minutes. Instantaneous wind speed values are also averaged, as V_{sr} . As a result, the average power value is over the theoretical power curve of the producer. V_{start} means the initial wind turbine speed, V_n – rated wind speed, V_{max} – cut-out wind speed, P_n – the device rated power. Explanatory variables should be selected skilfully, depending on the size of the farm. Variable selection is important for forecast accuracy.




Fig. 3. The average 10-minute value of energy (P_{sr}) (the largest dot) obtained in two-second measurements in the instantaneous wind speed (V_{sr}) function (1)

A wind farm with power rating of 50 MW may occupy an area of even several square kilometres. A farm can be divided into 2–3 smaller units connected together to a single transformer station. Division of a wind farm into smaller elements makes the power prediction even more difficult. With meteorological data from one measurement mast located far from the power plant, the prediction accuracy may be questionable. Difficulties in prediction for such structures are a result of large differences in instantaneous meteorological conditions at wind farms. The wind Speed on extensive wind farms can vary from 4 to 11 m/s. Fig. 4 can be used as an example; it shows the actual wind speeds on an extensive wind farm located in the northern part of Poland [1, 2].




Fig. 4. Actual wind speed on an extensive wind farm [1]

1.2. Meteorological forecasts

The accuracy of active power forecasts for wind farms is determined by meteorological factors. Wind speed is the main element that plays a significant role in power prediction. Because of the broad range of the subject, in the mentioned examples the authors took into account only one value crucial for power generation – wind force.

There are many methods for extrapolation of wind speed at the hub level. Below is the formula in which the wind parameter is dependent on the so-called terrain roughness (height above ground level).

$$V_h = v \cdot \frac{\ln \frac{h}{n}}{\ln \frac{h_0}{n}} \tag{1}$$

where: V_h – wind speed at height h [m/s], V – wind speed at height h_0 [m/s], h_0 – height of wind speed transmitter location [m], h – height for which the wind speed is calculated [m], n – roughness. Since the weather forecast is affected by a measurement error, the power prediction is also inaccurate. It is important to make as few such errors as possible in the long term.

The accuracy of wind power forecast is affected by a measurement error because the measurement masts are not located directly on wind farms. The wind speed measured in wind farms differs from the forecasts at a remote measurement mast. Fig. 5 shows how much the forecast wind speed may differ from its actual value. Deterministic models used for weather forecasting by meteorological companies may be misleading. Unfortunately, without adequate real-time monitoring of wind farm operation,

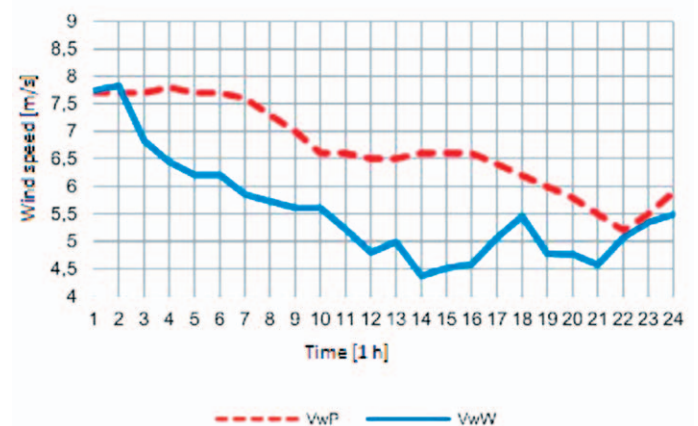


Fig. 5. The daily and hourly VwP forecast (red dashed line) and the actual VwW wind power of the entire wind farm (example of inaccurate weather forecast)

there is no choice other than to treat weather forecasts as reliable. Fig. 6 shows a good wind power forecast. With a high correlation ratio between the forecast and actual wind speed (0.97) it

is possible to estimate electrical energy with fair accuracy. Such a high dependency also indicates that weather forecasts may be trusted to some extent, but corrections should be taken into account when the data is entered into the model.

The cause of errors in the power forecast is a long distance between the measuring (meteorological) mast and the wind farm. An incorrect forecast of wind speed means large deviations of estimated power.




Fig. 6. The VwP forecast (red dashed line) and the actual VwW wind speed in the entire wind farm (1 day, an example of the expected weather forecast)

2. Forecast models

It should be borne in mind that the objective of searching for a useful forecast model is not the use of the highest possible number of parameters, which would describe the variability of time series as accurately as possible. The increase in the number of parameters means that the number of degrees of freedom is reduced and the power of applied statistical tests is lower. On the other hand, too high adjustment of series may include the description of not only the signal but also of random noise, for which accidental regularity may be perceived in completed tests [11]. The purpose of the search is to find a model that can describe the key characteristics of the particular case by using a limited number of statistically important parameters.

2.1. Physical model

A wind farm physical model can be built as a model of one replacement wind power plant with properly selected parameters or as a composition of many individual power plant models. In the latter case, the model would be more accurate (if parameters were available), but also more complex. A problem can be to determine the operation point for each power plant (Fig. 3). An unquestionable advantage of a replacement power plant model is the lower number of parameters; also, the averaging effect

occurring on a physical farm works in favour of that model. It may be difficult to select representative activations and to determine the parameters of a replacement power plant [1, 2].

The wind farm model reflects the farm power for certain forced elements, mainly wind speed and direction on the nacelle level. The wind from the nearest meteorological station may also be treated as a forced element for the farm model. The accuracy of the model whose function is to forecast the energy generation is satisfactory when the distance between the meteorological station and the wind farm location is less than 10 km [2]. The usefulness of the physical model was tested for the distance of no more than 5 km.

The wind farm model was built as a model of a replacement power plant with power rating equal to the total of individual power plants, subject to activation in the form of wind from a distant location of measuring mast and extrapolated to the hub height. It was assumed that the air parameters are slowly varying and constant over time between measurements. Changes in air density were taken into account; it changed by more than 10%, both in the summer (1.16–1.25 kg/m³) and in the winter (1.22–1.32 kg/m³).

The presented analytical model of wind farm is a simple model. It does not take into account the wake effect, which affects the accuracy. It was necessary to include the impact of the terrain type around the farm on the wind profile [2]. Therefore, the analytical method is one of the methods that can be used for prediction. However, such methods require adjustment of the model coefficients to the nature of the wind (dynamics of changes, seasons) and good knowledge of the particular farm. The use of various models and adjustment of parameters reduce errors to approximately 10%. There are suggestions to use separate models for day and night because of the different nature of the wind.

The wind farm power is the total of powers of individual plants. Even if they all are of the same type, the farm power is not a multiple of a single plant's power, as respective plants are subject to various forced elements. The power of a plant with the sweep area A , air speed V and air density ρ is determined by the following:

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

where: $C = f(l, b)$ is the power ratio which depends on the so-called specific speed $l = \omega R/V$ and the angle of blades in rotor b . Depending on the type of plant and on how it is controlled those parameters determine the characteristic $P = f(V)$ of the power plants where a typical shape is shown in Fig. 7.

Therefore, the power is the result of a non-linear conversion of wind speed and interference. It is assumed that the wind speed is the speed at the height of rotor axis.




Fig. 7. Power characteristics for a wind power plant

2.2. Linear regression model

Power forecasting as a linear combination of the previous and average power and trends is affected by large error due to non-linear dependence between the power and wind [1]. Non-linear regression would be more appropriate for power, but taking into account its accuracy and error distribution, it should not be recommended. The linear regression method could be successfully applied to wind prediction, provided that the prediction period is not too long. The proposals are included in [1, 2], where the expected wind speed is a linear function in previous moments, average speed and trend, such as the ARMA model below:

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - x_{sr})^2} \quad (3)$$

$$V_t = \sum_{j=1}^p a_j V_{t-1} + \sum_{k=G}^q b_k E_{t-k} \quad (4)$$

where: V_t means the wind speed at time t , whereas E means the average value.

If the wind farm owner is not able to obtain a weather forecast for the location, it may apply the linear regression method for power forecasting. Fig. 8 shows the results of using this method for power prediction with prediction steps of 3 and 6 hours, in accordance with the ARMA model.




Fig. 8. Wind farm power (P_c) and the power expected from the AR model with a period of 3h (P_{cP3h}) and 6h (P_{cP6h}) and the actual wind speed (V_t) as a function of time [2]

2.3. Neural model

As clearly shown in considerations for the analytical model, each wind farm has certain special features. It is necessary to take into account the characteristic feature in the wind farm modelling process. Besides the features that can be examined partly analytically, such as the wake effect or the vertical wind profile, there are also characteristics that are difficult to describe by analytical relations, e.g. wind distribution in the farm. However, they affect the wind speed at the location and power. A neural network may be used as an estimator which can reproduce the characteristic features.

A data set does not have to be large to create and verify the analytical model shown in the previous section. A larger set is necessary to create, learn and check a neural network. Based on the previous analyses [1, 2, and 9] we selected the Elman recurrent network for the purposes of this study to evaluate the usefulness of a neural farm model.

The model input was the wind force (marked in Fig. 9 as Input). The previous studies [1, 2] show that in certain periods, during the so-called dynamic weather, the wind dynamics also plays an important role, but this factor is not included in the neural model. As a result of the studies it was found that neither single-layer nor multi-layer networks were sufficiently good estimators. However, experience indicates that, similarly to the analytical model, the neural model should have a more complex structure. It is suggested to take into account not only the current wind value, but also the previous values, which would enable mapping of wind dynamics and changing of structure into a recurrent network. The Elman network with recurrence of hidden layer has been selected after the studies. The Elman network is characterised by a partial recurrence in the form of feedback between the hidden layer and the input layer. Fig. 9 shows the Elman network structure where: Input(t) – the number of external network inputs, Hidden – the number of neurons in the hidden layer, Output – the number of output neurons.




Fig. 9. The structure of Elman neural network

Several network learning algorithms were used in the studies; they were based on the backward error propagation. The best learning method was the Levenberg-Margardt method (marked as trainlm function in MATLAB). Studies were carried out on a large wind farm located on a uniform terrain, not by the sea; hence the phenomena described for the previous wind farm (such as high component for local wind in the summer) do not occur so frequently. Data from a well measured farm were used for creating the neural model, with access to a large number of data. Network learning was carried out with the use of data from an actual wind farm, i.e. the wind speed from the farm's measurement mast and the farm power measured at the transformer station. The power value for each plant was also available. Fig. 10–13 show the results of model operations, including a neural model. Actual wind speed is given at the network input, with the farm power forecast obtained at the output. Similar results were obtained for several other wind farms. Each farm must have its own model with a separate set of learning data.

2.4. Comparison of the results from forecast models

Fig. 10–13 compare the forecast results with the use of the forecast models discussed above. The colour markings are as follows: red – the power forecast with the use of a network (SSN), black – the power prediction for analytical model (Analit), brown – the power of regressive model (Reg), navy blue – the actual power production (Real), blue – the forecast wind force (Vw).




Fig. 10. Weather forecast with low reliability




Fig. 11. Weather forecast with high reliability




Fig. 12. Weather forecast with low reliability




Fig. 13. Weather forecast with high reliability

2.5. Evaluation of prediction error

Because of a varied increase of power at wind farms the forecast error is sometimes close to 0%, and then it exceeds 15%. Another issue is the method for calculating the percentage error for deviation of the forecast power from the actual power. The difference between the forecast variable and the forecast, or the absolute forecast error is calculated to verify the effectiveness of prediction methods. The first method is the normalized relative error of the BP forecast:

$$BP = \frac{|y_t - y_t^P|}{M} \cdot 100\% \quad (5)$$

where: y_t – power performance, y_t^P – power forecast, M – power rating of all wind farms.

This method (5) provides the information on how much more or less electricity has been generated by a single wind power plant in instantaneous meteorological conditions in relation to the manufacturer's restricted conditions. The method can be used to assess the deviation of the actual power from the theoretical power in wind power plants. This method has been published in many scientific and technical articles and it remains the best method available.

The second method is an absolute forecast error, which indicates the actual forecast error for wind farms. An absolute error is the difference between the actual and forecast value. Tab. 1 shows the average forecast errors – deviation of the forecast power from the actual power.

Forecast method	Average relative error [%]	Average absolute error
Analytical	9.6%	5.7771
Regressive	8.6%	4.7093

Tab. 1. The values of errors – deviation of the forecast power from the actual power

3. Final conclusions

Three structures of wind farm power estimators were examined as part of the study: physical, regressive and neural. The research shows that each forecast model may be used for prediction of power generated in wind power plants. A model based on linear regression methods may not be applied as the primary model because of the decreasing wind correlation in the long term. A model based on the description of physical phenomena may be an effective prediction tool, but it requires many parameters which are not always identified and precise knowledge of the farm, such as terrain topology or farm topology. That model does not require a large amount of data for verification. An analytical model may be a farm power estimator even when the information about wind comes from a location situated several kilometres away. A recursive neural network is a good estimator of wind farm power. It is able to reflect the farm's specific features, but it also requires a large set of learning data.

The quality of power forecasting depends not only on the power model, but also on the quality of weather forecasts.

A higher accuracy of power prediction for wind farms may be obtained with the use of a hybrid model by combining an “experienced” analytical model with a neural model. SSN are systems that can generalise, recognise and analyse the data which they have not processed before. The obvious fact is that humans do not have the computing capabilities of SSN, but SNN will never fully replace humans. However, it is important to note that with a skillful use of expert knowledge and mathematical tools known in the literature it is possible to create an effective forecast model. The access to historical actual wind conditions enables the evaluation of weather forecast accuracy for the structure. Based on the above it can be concluded that the more accurate the forecast is, the lower the costs of BM participants are. An accurate prediction of power generated in individual wind turbines and farms will decrease the volume of energy purchase/sale on the BM, and will enable a better use of the potential associated with the production of electricity by wind farms.

REFERENCES

- Bogalecka E., Rubanowicz T., Neuronowy model mocy farmy wiatrowej [*Neural model of wind farm power*], *Mechanik* 2010, issue 7, pp. 579–586.
- Bogalecka E., Rubanowicz T., Analiza charakterystyk parku wiatrowego [*Analysis of wind park characteristics*], *Wiadomości Elektrotechniczne* 2010, issue 2, pp. 15–20.
- Dobrzyński K., Przegląd systemów przeznaczonych do predykcji mocy wytwórczej w farmach wiatrowych [*Review of systems used for prediction of power generated in wind farm*], materials from the conference “Aktualne problemy w elektroenergetyce”, Jurata 2009.
- Giebel G. et al., Short-term Forecasting Using Advanced Physical Modelling, EWEC, Anemos Physical Modelling, 2006-02-08, The Results of the Anemos Project, Athens 2006.
- Instructions for Operation and Maintenance of Transmission Network, IRIESP, System balancing and management of system restrictions [online], www.pse-operator.pl.
- Joensen A., Short – term wind Power prediction, Ph.D. Thesis No. 108.
- Malko J., Predykcja mocy wytwórczych elektrowni wiatrowych [*Prediction of power generated in wind farms*], *Przegląd Elektrotechniczny* 2008, issue 9.
- Parkers J., Tindal A., Forecasting Short Term Wind Farm Production in Complex Terrain, Garrard Hassan and Partners Ltd. [online], www.gl-garradhassan.com.
- Rubanowicz T., Metody predykcji produkcji mocy parku wiatrowego [*Methods for prediction of power production in a wind park*], *Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej* 2008, issue 25.
- Website CIRE.pl, supervised by Agencja Rynku Energii SA [online], <http://www.rynek-bilansujacy.cire.pl/>.
- Website [online], www.gszafranski.w.interia.pl.

Zbigniew Prondziński

ENERGA-OBRÓT SA

e-mail: zbigniew.prondzinski@energa.pl

He graduated from the Faculty of Electrical and Control Engineering of the Gdańsk University of Technology, major in electrical engineering. He completed post-graduate studies in the field of corporate financial management and obtained an MBA. He is an authorised commodity broker. Since 1996 he has been involved in the power engineering industry. Employed in ENERGA-OBRÓT SA as the Head of Commercial and Technical Operator Department His area of interest includes mainly the operation of electricity and gas market.

Tomasz Rubanowicz

ENERGA-OBRÓT SA

e-mail: tomasz.rubanowicz@energa.pl

He graduated from the Military University of Technology in Warsaw (2006), major in mechatronics. He was a doctoral candidate at the Faculty of Electrical and Control Engineering of Gdańsk University of Technology. During his education he began to work in Elektrownie Wiatrowe SA involved in the development of wind farm projects, where for the first time he came across the subject of power forecasting for wind farms. He is currently employed in ENERGA-OBRÓT SA, where he is an expert in the prediction of power generated in wind farms. The areas of his scientific, research and professional interests include: the use of artificial intelligence for forecasting the dynamics of generation of renewable energy sources, electricity and gas market, off-shore wind energy technology.

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 140–148. When referring to the article please refer to the original text.

PL

Zryczałtowana usługa operatora handlowo-technicznego na potrzeby rozwoju energetyki wiatrowej w Polsce

Autorzy

Zbigniew Prondziński
Tomasz Rubanowicz

Słowa kluczowe

rynek bilansujący, elektrownie wiatrowe, prognozowanie

Streszczenie

Rozwój rynku energii elektrycznej sprawił, że branża energetyczna stała się atrakcyjna inwestycyjnie dla wielu przedsiębiorców. Trwający od kilku lat proces liberalizacji rynku energii elektrycznej przyczynił się do świadczenia nowych usług na rzecz inwestorów zainteresowanych rozwojem branży energetycznej. W ostatnich latach do grona najbardziej dynamicznie rozwijających się źródeł wytwórczych zalicza się elektrownie wiatrowe. Niewielu inwestorów zdaje sobie sprawę z konsekwencji przyłączenia elektrowni wiatrowych do krajowej sieci elektroenergetycznej, jak również z późniejszej eksploatacji tychże źródeł. Po zawarciu umowy sprzedaży energii elektrycznej inwestorzy zobowiązani są do prognozowania generacji mocy wytwórczej w horyzoncie dwudziestoczterogodzinnym z wyprzedzeniem dobowym. Charakter pracy elektrowni wiatrowych sprawia, że predykcja mocy nie należy do łatwych czynności i w efekcie właściciele ponoszą koszty za odchylenia na rynku bilansującym (niezbilansowanie). Powstające koszty mogą przyczynić się do braku płynności finansowej właściciela projektu, a w efekcie do bankructwa. Opcjonalnym rozwiązaniem dla właściciela farmy wiatrowej jest zryczałtowana usługa operatora handlowego.

W artykule przedstawiono analizę wybranych modeli prognostycznych, wykorzystywanych do predykcji mocy wytwórczej elektrowni wiatrowych, czynników wpływających na prognozy oraz model współpracy z kontrahentami poprzez usługę operatora handlowego.

1. Rynek energii elektrycznej

Rozwój rynku energii elektrycznej (REE) sprawił, że branża energetyczna stała się atrakcyjna inwestycyjnie dla wielu przedsiębiorców. Uruchomienie rynku bilansującego (RB) w 2001 roku było jednym z kroków ku liberalizacji REE. RB jest tzw. rynkiem technicznym, który służy do bieżącego bilansowania zapotrzebowania na energię elektryczną i wytwarzania energii elektrycznej w Krajowym Systemie Elektroenergetycznym (KSE). Na rynku dochodzi do realizacji zawartych przez uczestników umów kupna/sprzedazy energii i bilansowanie w czasie rzeczywistym zapotrzebowania na energię elektryczną z jej produkcją w KSE. Istnienie RB jest niezbędne dla funkcjonowania rynku energii, a udział w nim podmiotów kupujących energię jest obowiązkowy [1].

Funkcjonowanie RB możliwe jest jedynie dzięki zdolności szybkiego zwiększenia lub zmniejszenia produkcji energii elektrycznej przez jej wytwórców. Z tego powodu ceny energii na RB wyznaczone są na podstawie kontraktów zawieranych pomiędzy OSP a wytwórcami energii. Ceny energii kupowanej i odsprzedawanej przez uczestników rynku na RB oscylują wokół cen rynku konkurencyjnego. Uczestnictwo na RB na pewno wiąże się z kosztami i zdecydowanie wyższym poziomem ryzyka. Ceny na RB publikowane są z jednodniowym opóźnieniem i mogą przyjmować za 1 MWh wartości 70–1500 zł. W obydwu przypadkach są to więc transakcje niekorzystne dla klienta końcowego. W celu minimalizacji wolumenu transakcji na RB klienci kupujący energię na rynku konkurencyjnym starają się sporządzać możliwie najdokładniejsze prognozy jej zużycia.

Trwający od kilku lat proces liberalizacji rynku energii elektrycznej przyczynił się do świadczenia nowych usług na rzecz inwestorów zainteresowanych rozwojem branży

energetycznej. W ostatnich latach do grona najbardziej dynamicznie rozwijających się źródeł wytwórczych zalicza się elektrownie wiatrowe (EW). Niewielu inwestorów zdaje sobie sprawę z konsekwencji przyłączenia EW do KSE, jak również z późniejszej eksploatacji tychże źródeł. EW przyłączone do sieci są nie tylko źródłem przychodu, lecz także kosztem. Obowiązująca Instrukcja Ruchu i Eksploatacji Sieci Przesyłowej (IRiESP) reguluje zasady funkcjonowania REE. Z instrukcji wynika, że każdy właściciel jednostki wytwórczej przyłączonej do sieci zobowiązany jest do sporządzania grafików dobowo-godzinowych pracy obiektu. Predykcja mocy wytwórczej EW nie należy do łatwych czynności. Prognozy przygotowuje się w horyzoncie dwudziestoczterogodzinnym w dniu poprzedzającym dobę handlową. Wyprzedzenie dobowe wynika z wymagań kontraktowania mocy, a horyzont ten zależy od organizacji handlu i zróżnicowanych warunków handlowych (tzn. momentu zamknięcia bramki na RB). Prognozowanie polega na przewidzeniu wielkości produkcji energii elektrycznej z wyprzedzeniem w układzie dobowo-godzinowym. Prognozy sporządzane dla jednostki grafikonowej ENERGA-OBRÓT SA (EOB) obejmują klientów końcowych (odbiorców), jak i źródła wytwórcze. Na podstawie prognozy zapotrzebowania energii elektrycznej dokonuje się zakupu energii elektrycznej na rynku hurtowym (systemowym), żeby pokryć zapotrzebowanie odbiorców.

Do najtrudniej przewidywalnych źródeł wytwórczych, pod względem charakteru pracy, należą EW. Ich charakter pracy sprawia, że predykcja mocy nie należy do łatwych czynności i w efekcie właściciele ponoszą koszty za odchylenia na rynku bilansującym (za tzw. niezbilansowanie). Powstające koszty mogą przyczynić się

do braku płynności finansowej właściciela projektu, a w efekcie do bankructwa. Opcjonalnym rozwiązaniem dla właściciela farmy wiatrowej (FW) jest zryczałtowana usługa operatora handlowego (OH). Usługa jest rozszerzeniem współpracy pomiędzy inwestorem (OZE) a EOB poprzez zawarcie umowy OH. EOB, zawierając umowę OH, przejmuje na siebie koszty uczestnictwa FW na RB. W zamian wytwórca uiszcza na rzecz EOB zryczałtowaną opłatę (zł/MWh), uwarunkowaną od produkcji energii elektrycznej w danym okresie rozliczeniowym, mierzoną przez układ pomiarowo-rozliczeniowy. Dzięki umowie OH wytwórcy zyskują przede wszystkim prosty mechanizm w zakresie planowania kosztów dla FW, sporządzania biznesplanów oraz ograniczają własne ryzyko kosztów związane z uczestnictwem na RB.

Planowanie generacji mocy ma wpływ na bezpieczeństwo pracy KSE i handel energią elektryczną na rynku. Ze względu na coraz większą moc znamionową EW, przyłączoną do KSE, predykcja mocy odgrywa coraz bardziej istotną rolę. Według ÜRE szacunkowa moc całkowita zainstalowanych EW ma być zbliżona w 2013 roku do ok. 2000 MW, a w kolejnym 2014 roku do ok. 2500 MW.

Nieustannie od wielu lat prowadzone są różne badania nad modelami prognostycznymi. Innowacyjne rozwiązania przyczyniają się do poprawy pozycji podmiotów na konkurencyjnym rynku. Od 2002 roku na rynku dostępnych jest wiele różnych narzędzi do predykcji mocy źródeł wiatrowych, lecz o niezadowalającym błędzie prognozy, o których mowa w pozycjach [1–4]. Obecnie w prognozowaniu dużą popularnością cieszą się modele hybrydowe [5–7]. Autorzy niniejszej publikacji przedstawili trzy dowolnie wybrane metody prognostyczne, wykorzystywane m.in. w codziennej pracy oraz często spotykane

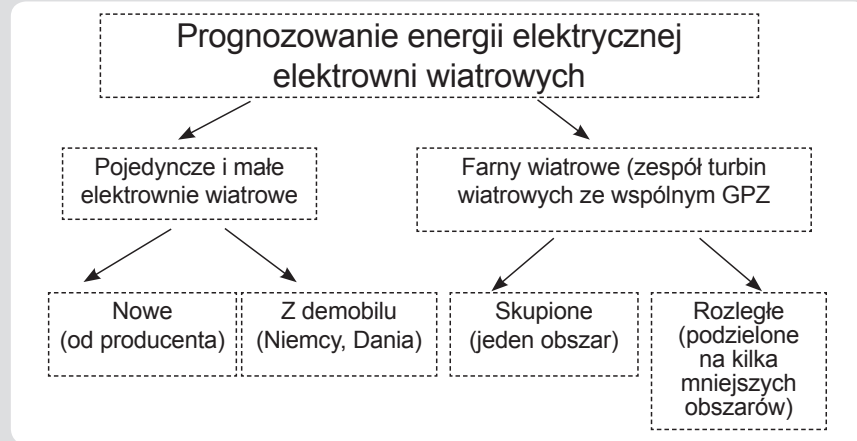
w literaturze fachowej [1–9]. Zastosowanie różnego rodzaju metod prognostycznych nigdy nie daje gwarancji uzyskania doskonałej prognozy. Do oczekiwanych rezultatów należy nieustannie podążać, pozyskując gruntowną wiedzę i doświadczenie operatorskie.

Szczególną uwagę warto zwrócić na możliwości wykorzystania sztucznych sieci neuronowych (SSN). Za pomocą modeli neuronowych możliwa jest predykcja generacji mocy wytwórczej dowolnej FW, pod warunkiem że posiada się dane historyczne generacji obiektu. ENERGA-OBRÓT SA (EOB), wychodząc naprzeciw oczekiwaniom rynkowym, umożliwiła kontrahentom rozliczanie za odchylenia poprzez stałą zryczałtowaną opłatę (OH), przejmując jednocześnie na siebie koszty, ryzyko i odpowiedzialność za niezbilansowanie. Odchyleniem nazywana jest różnica pomiędzy planowaną i zgłoszoną przez wytwórcę godzinową energią elektryczną, a godzinową energią elektryczną rzeczywiście wyprodukowaną i wprowadzoną do sieci dystrybucyjnej, pomierzoną przez układ pomiarowy. Usługa operatora handlowego (OH) jest dobrą alternatywą dla właścicieli EW. Dzięki usłudze OH oszacowanie przychodów i kosztów, związanych z funkcjonowaniem EW na rynku, jest prostsze ze względu na stałą opłatę. Tego typu opcja nie rozwiązała jednak problemu predykcji i dalszego ponoszenia kosztów za odchylenia.

EOB, mając na swoim terenie wytwórców i odbiorców, zobowiązana jest do szacowania ilości potrzebnej energii elektrycznej dla jednostki grafikowej. Zakładając, że EW (wytwórcy) wyprodukują i wprowadzą do sieci w ciągu doby lub godziny na rynku hurtowym (systemowym) energię np. 100 MWh, a zapotrzebowanie na energię (odbiorcy) wyniesie 1500 MWh, to spółka EOB będzie musiała zakupić na rynku hurtowym energię 1000 MWh. Dokładna predykcja mocy wytwórczej EW zmniejsza koszty partycypacji uczestników na obowiązkowym RB.

Krótkoterminowa predykcja dobowo-godzinowa mocy wytwórczej EW nie należy do łatwych zadań ze względu na stochastyczny charakter wymuszenia (wiatru) oraz strukturę budowy obiektu. Produkcja energii elektrycznej nie wynika wyłącznie z zainstalowanej mocy znamionowej siłowni wiatrowej, ale przede wszystkim z wartości chwilowej prędkości wiatru, wyrażonej w trzeciej potęgze. Zmieniające się na przestrzeni doby warunki meteorologiczne powodują dużą niestalość produkcji energii. Ze względu na losową wartość mocy czynnej dokładne jej oszacowanie w dłuższym horyzoncie czasowym jest trudne. Oczywiście jest również, że im dłuższy okres szacunkowy, tym większy błąd prognozy. Dynamika warunków meteorologicznych sprawia, że EW zaliczane są do „niespokojnych” źródeł generacji mocy czynnej.

Tendencja rozwojowa EW (szybki przyrost mocy nominalnej w KSE) sprawia, że prognozowanie stopniowo odgrywa coraz większą rolę w poprawie bezpieczeństwa energetycznego. Na potrzeby predykcji mocy EW można dokonać klasyfikacji, chociażby pod względem jednostkowej mocy znamionowej (rys. 1). Typowe siłownie wykorzystywane w energetyce są jednostkami o małej i dużej mocy znamionowej. Do małych mocy zaliczają się pojedyncze siłownie (poniżej 850 kW) i małe farmy do 2 MW.



Rys. 1. Klasyfikacja EW na potrzeby prognozowania produkcji energii elektrycznej

Utrzymującym się trendem w energetyce wiatrowej jest budowanie FW, a nie pojedynczych siłowni. Farmy składają się z zespołu od kilku do kilkunastu siłowni wiatrowych, podłączonych do stacji transformatorowej (400/110 kV). Obecnie moc znamionowa największej FW w Polsce sięga nawet 120 MW.

Na podstawie literatury można wyróżnić trzy zasadniczo odmienne podejścia łączące prognozę wiatrową z mocą wyjściową siłowni [7], tj.:


1. Podejście fizyczne – oparte na samej naturze konwersji mocy strugi powietrza na moc elektryczną
2. Podejście statystyczne – opisujące związek pomiędzy prognozowanymi parametrami wiatru a wyjściową mocą elektryczną na drodze analizy statystycznej szeregów czasowych z przeszłości
3. Podejście „uczące” – wykorzystujące metody sztucznej inteligencji do uzyskania relacji pomiędzy prognozą wiatru a mocą oddawaną w postaci szeregów czasowych.

W celu uzyskania dokładniejszych prognoz stosuje się podejście hybrydowe, łączące ze sobą w jeden model zaprezentowane wcześniej podejścia. Pomimo dysponowania danymi oraz gotowymi modelami matematycznymi predykcja bez odpowiedniej wiedzy i doświadczenia może okazać się nieskuteczna, a z czasem kosztowna.

W modelach hybrydowych wykorzystuje się różnego rodzaju dane, tj. podstawową zależność wielkości mocy od siły wiatru, charakterystykę mocy producenta, informacje o planowanych wyłączeniach z pracy EW oraz prognoz meteorologicznych (siły i kierunku wiatru, ciśnienia atmosferycznego i temperatury powietrza – uwzględniając dzięki temu porę roku). Wiedzę i doświadczenie można osiągnąć dzięki wieloletnim obserwacjom pracy źródeł wiatrowych.

Podejście fizyczne obejmuje zestaw modeli uwzględniających:

- warunki wiatrowe w badanej lokalizacji (dynamikę zmian) i wysokość gondoli siłowni



Rys. 2. Charakterystyki krzywych mocy pięciu siłowni wiatrowych w funkcji prędkości wiatru (pomiarzy w okresie letnim, przy dużej zmienności wiatru) [1]

- efekt wzajemnego oddziaływania masztów siłowni wiatrowych (przesłonięcie)
- charakterystykę elektromechaniczną siłowni (krzywą mocy)
- statystykę mocy wyjściowej.


Istnieją metody uczenia i samouczenia pozwalające uzyskać celowe i skuteczne działanie nawet w sytuacji, kiedy twórca nie zna algorytmu, według którego można rozwiązać postawione zadanie. Sieć działa zawsze jako całość i poszczególne jej elementy mają wkład w realizację wszystkich czynności, które sieć realizuje. Jedną z konsekwencji takiego działania sieci jest jej zdolność do poprawnego działania, nawet przy niepełnych danych.

1.1. Rzeczywiste charakterystyki


Dobór charakterystyki mocy (krzywej producenta) bez doświadczenia operatorskiego może okazać się trudny i niewystarczający. Rzeczywista charakterystyka mocy przez większą część roku nie pokrywa się z teorią. Do czynników utrudniających szacowanie mocy zaliczają się warunki wewnętrzne (m.in. struktura budowy farmy) oraz zewnętrzne (meteorologiczne), co widoczne jest w postaci rozrzutu mocy na rys. 2. Rozrzut mocy wynika z dynamiki zmiany kierunku wiatru, położenia gondoli i dynamiki płatów oraz braku okresowej kalibracji anemometrów.

Zjawisko rozrzutu mocy występuje przeważnie w okresie letnim, kiedy wartość prędkości i kierunku wiatru zmienia się dynamicznie. Na rys. 2 przedstawiono krzywą mocy z rozrzutem mocy w zakresie pracy siłowni od 4 do 15 m/s. Punkty znajdujące się pod teoretyczną krzywą mocy (oznaczone niebieskimi kropkami) są zrozumiałe. Mniejsza moc, dla chwilowej prędkości wiatru, wynika z dynamiki zmiany kierunku wiatru, zmiany kąta położenia płatów (dużej bezwładności wirnika), zmiany kąta położenia gondoli, ograniczeń technicznych (np. wysokiej temperatury przekładni zębatej), a także z mechaniki urządzenia (tj. drgań mechanicznych płatów, wału generatora, wieży i innych elementów).

Przyczyną jest również zmienność gęstości powietrza i wilgotności. Natomiast moc wygenerowana nad teoretyczną krzywą spowodowana jest dynamiką zmiany kierunku wiatru i gondoli, a również najprawdopodobniej błędem pomiarowym (np. rozregulowanym anemometrem lub brakiem okresowej kalibracji anemometru).



Rys. 3. Wartość średnia energii P_{sr} (największa kropka) 10-minutowa otrzymana z pomiarów dwusekundowych w funkcji chwilowej prędkości wiatru V_{sr} [1]



Rys. 4. Rzeczywista prędkość wiatru na rozległej FW [1]


Rozrzut mocy, która jest w trzeciej potęgze, może wynikać także z dużej wartości chwilowej podmuchów wiatru. Wartości chwilowe mocy i prędkości wiatru uśredniane są za ostatnie 10 min i przekazywane do układu sterowania przetwarzającego wyniki pomiaru oraz gromadzącego uśrednione dane pomiarowe. Za przykład niech posłuży rys. 3, punkt pomiarowy (mniejsze kropki) to wartość energii za czas 2 sek.

Na rys. 3 przedstawiono średnią wartość energii elektrycznej za ostatnie 10 min, na tle teoretycznej krzywej mocy, w funkcji chwilowej prędkości wiatru. P_{sr} oznacza średnią wartość energii po 10 min. Chwilowe wartości prędkości wiatru również zostały uśrednione V_{sr} . W efekcie średnia wartość mocy jest nad teoretyczną krzywą mocy producenta. V_{start} oznacza startową prędkość turbiny wiatrowej, V_n – znamionową prędkość wiatru, V_{max}


– wyłączeniową prędkość wiatru, P_n – znamionową moc urządzenia.

W zależności od wielkości prognozowanej farmy należy umiejętnie dobrać zmienne objaśniające. Dobór zmiennych ma duże znaczenie na dokładność prognozy.

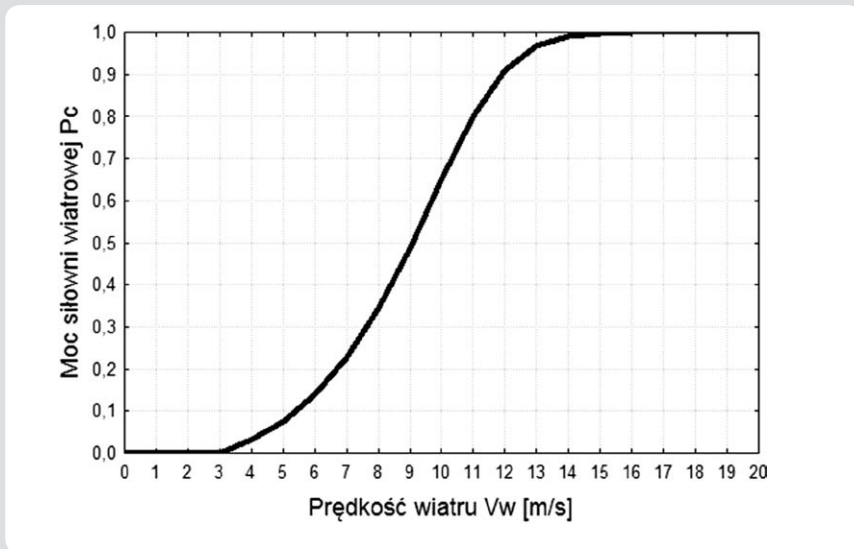
FW o mocy znamionowej 50 MW może zajmować powierzchnię nawet kilkunastu kilometrów kwadratowych. Farma może być podzielona na 2–3 mniejsze zespoły, podłączone wspólnie do jednej stacji transformatorowej. Podział FW na mniejsze dodatkowo utrudnia predykcję mocy. Dysponując danymi meteorologicznymi z jednego masztu pomiarowego, oddległego od siłowni, dokładność predykcji może budzić wątpliwości. Trudność predykcji takich obiektów wynika z dużej różnicy chwilowych warunków meteorologicznych panujących na FW. Prędkość wiatru na rozległej FW może wahać się od 4 do 11 m/s. Za przykład posłużyć może rys. 4,



Rys. 5. Przebieg dobowo-godzinowy prognozowanej V_{wP} (linia czerwona, przerywana) i rzeczywistej siły wiatru V_{wW} całej FW (przykład niedokładnej prognozy pogody)



Rys. 6. Przebieg prognozowanej VwP (linia czerwona, przerywana) i rzeczywistej prędkości wiatru VwW całej FW (1 doba, przykład oczekiwanej prognozy pogody)



Rys. 7. Charakterystyka mocy siłowni wiatrowej

na którym przedstawiono rzeczywiste prędkości wiatru na rozległej FW, zlokalizowanej w północnej części kraju [1, 2].

1.2. Prognoza warunków meteorologicznych

Dokładność prognoz mocy czynnej FW uwarunkowana jest od czynników meteorologicznych. Głównym elementem, który odgrywa znaczącą rolę w predykcji mocy, jest wartość prędkości wiatru. Ze względu na szeroką tematykę autorzy, przywołując przykłady, brali pod uwagę tylko jedną, najważniejszą wartość wpływającą na generację mocy – siłę wiatru.

Istnieje wiele metod ekstrapolacji prędkości wiatru na poziom piasty. Obok przedstawiono wzór uzależniający parametr wiatru od tzw. długości szorstkości terenu (wysokości nad poziomem ziemi).

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

gdzie: V_h – prędkość wiatru na wysokości h [m/s], V – prędkość wiatru na wysokości h_0 [m/s], h_0 – wysokość usytuowania nadajnika prędkości wiatru [m], h – wysokość, dla której obliczana jest prędkość wiatru [m], n – szorstkość.

W związku z tym, że prognoza pogody jest obciążona błędem pomiarowym, to również predykcja mocy będzie niedokładna. Ważne jest to, aby takich błędów popełniać jak najmniej w dłuższym horyzoncie czasowym. Dokładność prognozy siły wiatru obciążona jest błędem pomiarowym, ponieważ maszty pomiarowe nie są posadowione bezpośrednio

na FW. Wartość prędkości wiatru pomierzona na FW różni się od prognozowanej z odległego masztu pomiarowego. Na rys. 5 pokazano, jak dalece mogą różnić się wartości prognozowanej prędkości wiatru od rzeczywistej. Modele deterministyczne, służące do prognozowania pogody, z których korzystają firmy meteorologiczne, mogą wprowadzać w błąd. Niestety, bez odpowiedniego monitoringu w czasie rzeczywistym pracy FW jest się zmuszonym traktować prognozę pogody jako wiarygodną.

Na rys. 6 przedstawiono dobrą prognozę siły wiatru. Dzięki wysokiemu współczynnikowi korelacji między prognozowaną prędkością wiatru a rzeczywistą – wynoszącemu 0,97 – można w miarę dokładnie oszacować energię elektryczną. Tak wysoka zależność informuje również o tym, że można w pewnym stopniu zaufać prognozom pogody, ale należy uwzględnić korekty podczas wprowadzania danych do modelu.

Przyczyną powstawania błędów w prognozie mocy jest duża odległość posadowienia masztu pomiarowego (meteorologicznego) od FW. Błędna prognoza prędkości wiatru niesie ze sobą duże odchylenia prognozowanej mocy.

2. Modele prognostyczne

Należy pamiętać, że celem poszukiwań użytecznego modelu prognostycznego nie jest użycie jak największej liczby parametrów, które jak najdokładniej opiszą zmienność szeregu czasowego. Wraz ze wzrostem liczby parametrów spada liczba stopni swobody i osłabia się moc stosowanych testów statystycznych. Z kolei zbyt duże dopasowanie szeregu może objąć opis nie tylko części procesu zwanej sygnałem, ale i losowego szumu, dla którego w skończonych próbach można dopatrywać się przypadkowych regularności [11]. Celem poszukiwań jest odkrycie takiego modelu, który za pomocą ograniczonej liczby statystycznie istotnych parametrów opisze najważniejsze cechy badanego przypadku.

2.1. Model fizyczny

Model fizyczny FW można zbudować jako model jednej zastępczej siłowni wiatrowej o odpowiednio dobranych parametrach albo jako złożenie modeli wielu pojedynczych siłowni. W drugim przypadku model byłby bardziej dokładny (przy dostępności parametrów), ale i bardziej złożony. Problemem może być określenie punktu pracy każdej siłowni ma niewątpliwą zaletę, jaką jest mniejsza liczba parametrów, a efekt uśredniania występujący na fizycznej farmie działa na korzyść tego modelu. Trudnością może być wybranie reprezentatywnych pobudeń oraz określenie parametrów zastępczej siłowni [1, 2].

Model FW odtwarza moc farmy dla określonych wymuszeń, z których głównymi są prędkość i kierunek wiatru na wysokości gondoli. Można jako wymuszenie dla modelu farmy potraktować wiatr z najbliższej stacji meteorologicznej. Dokładność modelu, którego funkcją jest prognozowanie produkcji energii jest zadowalająca, gdy odległości między stacją meteorologiczną a lokalizacją EW jest mniejsza niż 10 km [2]. W ramach pracy zbadano przydatność modelu fizycznego, gdy odległość ta nie przekracza 5 km.

Model FW zbudowano jako model zastępczej siłowni o mocy znamionowej równej sumie mocy pojedynczych siłowni, poddanej pobudzeniu w postaci wiatru z odległej lokalizacji masztu pomiarowego i ekstrapolowanego do wysokości piasty. Założono, że parametry powietrza jako wolnozmiennie są stałe w czasie pomiędzy pomiarami. Uwzględniono zmiany gęstości powietrza, która zmieniała się o ponad 10% zarówno w okresie letnim (1,16 – 1,25 kg/m³), jak i zimowym (1,22 – 1,32 kg/m³). Przedstawiony model analityczny FW jest modelem prostym. Nie uwzględnia np. zjawiska przesłonięcia, co odbija się na dokładności. Konieczne okazało się uwzględnienie wpływu charakteru terenu wokół farmy na profil wiatru (2). Metoda analityczna jest więc jedną z metod, które mogą być stosowane do predykcji. Wymagają jednak dopasowania współczynników modelu do charakteru wiatru (dynamiki zmian, pory roku) oraz dobrej znajomości konkretnej farmy. Zróżnicowanie modeli i dopasowanie parametrów zmniejsza błąd do ok. 10%. Spotyka się propozycje stosowania odrębnych modeli dla dnia i nocy właśnie ze względu na inny charakter wiatru. Moc farmy wiatrowej jest sumą mocy poszczególnych elektrowni. Nawet jeżeli wszystkie są tego samego typu, to moc farmy nie jest wielokrotnością mocy jednej elektrowni, ponieważ poszczególne siłownie

są poddane różniącym się wymuszeniom. Moc siłowni o powierzchni omiatania A , przy prędkości powietrza V i gęstości ρ określona jest zależnością:

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

gdzie: $C_p = f(l, b)$ jest współczynnikiem mocy zależnym od tzw. wyróżnika szybkobieżności $l = \omega R/V$ i kąta ustawienia łopaty wirnika b . Zależnie od rodzaju elektrowni i sposobu jej sterowania parametry te kształtują charakterystykę $P = f(V)$ elektrowni, której typowy kształt pokazano na rys. 7.

Moc jest więc wynikiem nieliniowego przekształcenia prędkości wiatru oraz oddziaływania zakłóceń. Za prędkość wiatru przyjmuje się prędkość na wysokości osi wirnika.

2.2. Model regresji liniowej

Prognozowanie mocy jako kombinacji liniowej mocy poprzedniej, średniej i trendów jest obarczone dużym błędem ze względu na nieliniową zależność mocy od wiatru (1). W przypadku mocy właściwsza byłaby regresja nieliniowa, ale biorąc pod uwagę jej dokładność i rozkład błędów, nie powinna być polecana. Metoda regresji liniowej może być natomiast z powodzeniem stosowana do predykcji wiatru, pod

warunkiem, że okres predykcji nie jest zbyt długi. Propozycje zawarte są m.in. w [1, 2], gdzie przewidywana prędkość wiatru jest funkcją liniową prędkości w chwilach poprzednich, średniej i trendu, np. model ARMA, jak poniżej:

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - x_{sr})^2} \quad (3)$$

$$V_t = \sum_{j=1}^p a_j V_{t-j} + \sum_{k=G}^q b_k E_{t-k} \quad (4)$$

gdzie: V_t oznacza prędkość wiatru w chwili t , a E oznacza wartość średnią.

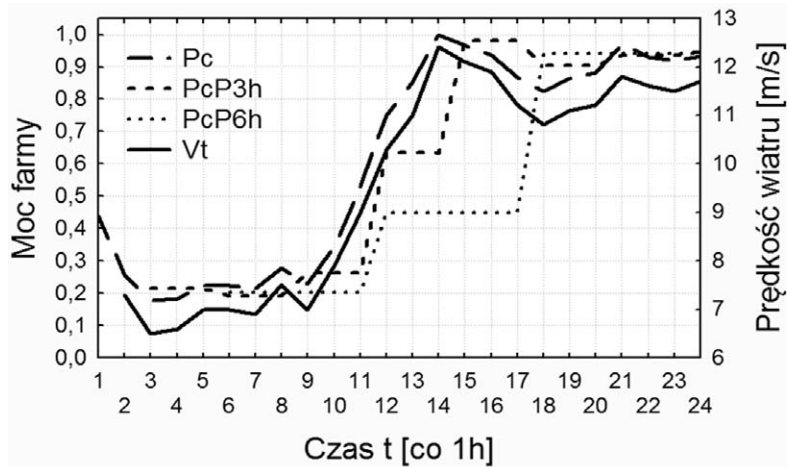
Jeżeli właściciel FW nie dysponuje prognozą pogody dla lokalizacji, to może do prognozowania mocy zastosować metodę regresji liniowej. Na rys. 8 pokazano wyniki zastosowania tej metody do predykcji mocy z krokiem predykcji 3 i 6 godzin, zgodnie z modelem ARMA.

2.3. Model neuronowy


Jak wynika z rozważań przeprowadzonych dla modelu analitycznego, każda FW ma pewne cechy szczególne, osobnicze. Uwzględnienie cech charakterystycznych jest konieczne w procesie modelowania FW. Poza takimi, które można ująć częściowo analitycznie, jak przesłonięcie czy pionowy profil wiatru, są też cechy, trudne do opisania zależnościami analitycznymi, jak rozkład wiatru na farmie. Mają one jednak wpływ na prędkość wiatru w danej lokalizacji i moc. Jako estymator, który może odwzorzyć te cechy charakterystyczne, można wykorzystać sieć neuronową.

Do zbudowania i weryfikacji modelu analitycznego, przedstawionego w poprzednim punkcie, nie jest wymagana duża liczebność zbioru danych. Na potrzeby skonstruowania, nauczania i sprawdzenia sieci neuronowej potrzebny jest zbiór bardziej liczny. Na podstawie wcześniejszych analiz [1, 2, 9] do oceny przydatności neuronowego modelu farmy, na potrzeby niniejszego artykułu, wybrano sieć rekurencyjną Elmana.


Wejściem modelu była siła wiatru (oznaczona na rys. 9 jako Input). Wcześniejsze badania [1, 2] wskazują, że w pewnych okresach, przy tzw. dynamicznej pogodzie, istotną rolę odgrywa też dynamika wiatru, ale w modelu neuronowym nie uwzględniono tego czynnika. W wyniku badań stwierdzono, że ani sieć jednowarstwowa, ani badana sieć wielowarstwowa nie okazały się wystarczająco dobrymi estymatorami. Doświadczenie pozwala jednak na stwierdzenie, że podobnie jak przy modelu analitycznym, tak i model neuronowy powinien mieć strukturę bardziej złożoną. Proponuje się uwzględnienie nie tylko wartości aktualnej wiatru, ale także wartości poprzednich, co pozwoli na odwzorowanie dynamiki wiatru oraz zmianę struktury na sieć rekurencyjną. Po badaniach wybrano sieć Elmana z rekurencją warstwy ukrytej. Sieć Elmana charakteryzuje się częściową rekurencją w postaci sprzężenia zwrotnego między warstwą ukrytą a warstwą wejściową. Na rys. 9 przedstawiono strukturę sieci Elmana, przy czym: Input(t) – liczba wejść zewnętrznych sieci, Hidden – liczba neuronów w warstwie ukrytej, Output – liczba neuronów wyjściowych sieci.




Rys. 8. Moc FW (P_c) oraz moc przewidywana z modelu AR z okresem 3h (P_{cP3h}) i 6h (P_{cP6h}) oraz rzeczywista prędkość wiatru (V_t) w funkcji czasu [2]




Rys. 9. Struktura sieci neuronowej Elmana



Rys. 10. Progniza pogody o niskim stopniu sprawdzalności



Rys. 11. Progniza pogody z wysokim stopniem sprawdzalności



Rys. 12. Progniza pogody o niskim stopniu sprawdzalności

W badaniach wykorzystano kilka algorytmów uczenia sieci, opartych na zasadzie wstecznej propagacji błędu. Najlepszą metodą uczenia okazała się metoda Levenberga-Marguardta (oznaczona w MATLAB-ie funkcją *trainlm*). Badania prowadzono na danych dużej FW położonej na jednolitym terenie, nie nad brzegiem morza, stąd zjawiska opisane dla poprzedniej farmy (m.in. duża składowa wiatru lokalnego latem) nie wystąpiły tak mocno. Do zbudowania modelu neuronowego użyto danych z dobrze opomiarowanej farmy i przy dostępności do dużej liczby danych. Uczenie sieci odbywało się na danych pochodzących z rzeczywistej FW, a więc prędkości wiatru z masztu pomiarowego na farmie i mocy farmy zmierzonej w GPZ. Dysponowano także mocą każdej siłowni. Na rys. 10–13 pokazano wyniki działania modelu, m.in. neuronowego. Na wejściu sieci podano przebieg rzeczywistej prędkości wiatru, a na wyjściu otrzymano prognozę mocy farmy. Podobne wyniki uzyskano dla kilku innych FW. Każda farma musi mieć swój model, z osobnym zbiorem danych uczących.

2.4. Porównanie wyników prognoz modeli prognostycznych

Na rys. 10–13 porównano wyniki prognozy przy użyciu omówionych powyżej modeli prognostycznych. Kolorem czerwonym oznaczono prognozę mocy przy użyciu sieci (SSN), czarnym predykcję mocy modelu analitycznego (Analit), brązowym moc modelu regresyjnego (Reg), granatowym rzeczywistą produkcję mocy (Real), a niebieskim prognozowaną wartość siły wiatru (Vw).


2.5. Ocena błędu predykcji

Zróżnicowany przyrost mocy EW powoduje, że błąd prognozy raz jest bliski 0%, a następnym razem przekracza 15%. Odrębnym tematem jest metoda liczenia błędu procentowego odchylenia prognozowanej mocy od rzeczywistej. W celu sprawdzenia skuteczności metod predykcji najczęściej wylicza się różnicę między zmienną prognozowaną a prognozą lub bezwzględny błąd prognozy. Pierwszą metodą jest znormalizowany względny błąd prognozy BP:

$$BP = \frac{|y_t - y_t^p|}{M} \cdot 100\% \quad (5)$$

gdzie: y_t – wykonanie mocy, y_t^p – prognoza mocy, M – moc znamionowa wszystkich EW.

Dzięki tej metodzie (5) uzyskuje się informację, o ile mniej lub więcej energii elektrycznej wyprodukowała pojedyncza siłownia wiatrowa w chwilowych warunkach meteorologicznych, względem zastrzeżonych warunków producenta. Metoda umożliwia ocenę błędu odchylenia mocy rzeczywistej od teoretycznej siłowni wiatrowych. Metoda ta została opublikowana w wielu branżowych artykułach naukowo-technicznych i nie opracowano do tej pory lepszej. Drugą metodą jest bezwzględny błąd prognozy, który informuje o rzeczywistym błędzie prognozy EW. Błąd bezwzględny to różnica między wartością rzeczywistą a prognozowaną. W tab. 1 przedstawiono



Rys. 13. Prognoza pogody z wysokim stopniem sprawdzalności

wartości średnie błędów odchylenia mocy prognozowanej od rzeczywistej.

Metoda prognostyczna	Średni błąd względny [%]	Średni błąd bezwzględny
Analityczna	9,6%	5,7771
Regresyjna	8,6%	4,7093
Neuronowa	9,2%	5,1759

Tab. 1. Wartości błędów odchylenia mocy prognozowanej od rzeczywistej

3. Wnioski końcowe

W ramach pracy przebadano trzy struktury estymatorów mocy FW: fizycznego, regresyjnego i neuronowego. Z badań wynika, że każdy model prognostyczny można wykorzystywać na potrzeby predykcji mocy wytwórczej elektrowni wiatrowych. Model oparty na metodach regresji liniowej nie może być stosowany jako model podstawowy, ze względu na malejącą korelację wiatru w dłuższym horyzoncie czasowym. Model oparty na opisie zjawisk fizycznych

może być skutecznym narzędziem predykcji, ale wymaga wielu parametrów, które nie zawsze są zidentyfikowane, oraz dokładnej wiedzy o farmie, jak topologia terenu czy topologia farmy. Nie jest wymagana duża liczba danych do weryfikacji modelu. Model analityczny może być estymatorem mocy farmy, nawet gdy dane o wietrze pochodzą z lokalizacji odległej o kilka kilometrów. Sieć neuronowa rekurencyjna jest dobrym estymatorem mocy FW. Potrafi odtworzyć cechy charakterystyczne farmy, wymaga jednak dużego zbioru danych uczących. Jakość prognozowania mocy zależy nie tylko od modelu mocy, ale także od jakości prognozy pogody.

Chcąc uzyskać większą dokładność predykcji mocy FW, można zbudować model hybrydowy poprzez połączenie ze sobą „doświadczonego” modelu analitycznego z modelem neuronowym. SSN to systemy, które mają zdolność generalizacji, rozpoznawania i analizy danych, z którymi wcześniej nie miały do czynienia. Oczywistym faktem jest, że człowiek nie dysponuje takimi umiejętnościami obliczeniowymi jak SSN, a SNN nie zastąpi w pełni człowieka. Należy jednak pamiętać, że umiejętne wykorzystanie wiedzy eksperckiej i znanych w literaturze narzędzi matematycznych

umożliwia zbudowanie skutecznego modelu prognostycznego. Dostęp do historycznych, rzeczywistych warunków wiatrowych daje możliwość oceny dokładności prognozy pogody danego obiektu. Na podstawie powyższego można wnioskować, że im dokładniejsza prognoza, tym mniejsze koszty funkcjonowania uczestników na RB. Dokładna predykcja mocy wytwórczych pojedynczych turbin i farm wiatrowych zmniejszy wielkość zakupu/sprzedaży energii na RB, a także pozwoli lepiej wykorzystać potencjał związany z produkcją energii elektrycznej przez EW.

Bibliografia

1. Bogalecka E., Rubanowicz T., Neuronowy model mocy farmy wiatrowej, *Mechanik* 2010, nr 7, s. 579–586.
2. Bogalecka E., Rubanowicz T., Analiza charakterystyk parku wiatrowego, *Wiadomości Elektrotechniczne* 2010, nr 2, s. 15–20.
3. Dobrzyński K., Przegląd systemów przeznaczonych do predykcji mocy wytwórczej w farmach wiatrowych, materiały konferencji „Aktualne problemy w elektroenergetyce”, Jurata 2009.
4. Giebel G. i in., Short-term Forecasting Using Advanced Physical Modelling, EWEC, Anemos Physical Modelling, 2006-02-08, The Results of the Anemos Project, Athens 2006.
5. Instrukcja Ruchu i Eksploatacji Sieci Przesyłowej, IRiESP, Bilansowanie systemu i zarządzanie ograniczeniami systemowymi [online], www.pse-operator.pl.
6. Joensen A., Short – term wind Power prediction, Ph.D. Thesis No. 108.
7. Malko J., Predykcja mocy wytwórczych elektrowni wiatrowych, *Przegląd Elektrotechniczny* 2008, nr 9.
8. Parkers J., Tindal A., Forecasting Short Term Wind Farm Production in Complex Terrain, Garrard Hassan and Partners Ltd. [online], www.gl-garradhassan.com.
9. Rubanowicz T., Metody predykcji produkcji mocy parku wiatrowego, *Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej* 2008, nr 25.
10. Strona internetowa CIRE.pl, która jest pod nadzorem Agencji Rynku Energii SA [online], <http://www.rynek-bilansujacy.cire.pl/>.
11. Strona internetowa [online], www.gsz-franski.w.interia.pl.

Zbigniew Prondziński

mgr inż.

ENERGA-OBRÓT SA

e-mail: zbigniew.prondzinski@energa.pl

Absolwent Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej, kierunek elektroenergetyka. Ukończył studia podyplomowe z zakresu zarządzania finansami przedsiębiorstw oraz uzyskał dyplom MBA. Posiada uprawnienia maklera giełd towarowych. Od 1996 roku związany z branżą energetyczną. Zatrudniony w spółce ENERGA-OBRÓT SA na stanowisku dyrektora departamentu operatora handlowo-technicznego. Jego obszar zainteresowań to przede wszystkim funkcjonowanie rynku energii elektrycznej oraz paliwa gazowego.

Tomasz Rubanowicz

mgr inż.

ENERGA-OBRÓT SA

e-mail: tomasz.rubanowicz@energa.pl

Absolwent Wojskowej Akademii Technicznej w Warszawie (2006), kierunek mechatronika. Podjął studia doktoranckie na Wydziale Elektrotechniki i Automatyki Politechniki Gdańskiej.

Jeszcze w trakcie studiów rozpoczął pracę w firmie Elektrownie Wiatrowe SA, zajmującej się rozwojem projektów farm wiatrowych, w której to po raz pierwszy spotkał się z tematyką prognozowania mocy wytwórczej elektrowni wiatrowych. Obecnie pracuje w ENERGA-OBRÓT SA, gdzie zajmuje się zawodowo m.in. predykcją mocy wytwórczej elektrowni wiatrowych.

Do obszarów jego zainteresowań naukowo-badawczych i zawodowych należą: zastosowanie metod sztucznej inteligencji na potrzeby prognozowania dynamiki generacji odnawialnych źródeł energii, rynek energii elektrycznej i paliwa gazowego, technologia morskiej energetyki wiatrowej.