

Selected Tools For Wind Farm Output Daily-Hourly Forecasting For The Wholesale Market

Author

Tomasz Rubanowicz

Keywords

short-term forecasting, wind farms, artificial neural networks

Abstract

Owners of generating sources after their connection to the power grid become participants of the electricity market, including the balancing market. From that moment on, each participant is obliged to forecast their own generating units' output with a specified advance time. The adopted energy transformation policy removes investment restrictions, in particular concerning the so-called distance act (10H), which stopped the dynamic development of this technology on land. This approach will contribute to the construction of more wind farms. The greater the number of generation sources dependent on weather conditions, the more difficult their predictability and the greater the risk of trade imbalances in participants' purchasing portfolios. Every incorrect energy forecast that differs from the actual output will result in higher costs of participation in the market. Effective output forecasting allows companies to reduce the cost of their participation. This paper presents a method of forecasting wind farm output using artificial neural networks, which can be an alternative tool for analytical and statistical models. This paper aims to evaluate the effectiveness of the farm output forecast model, i.e. the output modelling for specific weather conditions. The paper presents the farm output affecting factors that should be included in the model, and it shows that the neural network can reproduce farm output curves similar to the catalogue curves with consideration of the object's characteristics. The author has exhaustively researched the subject for 10 years, reaching the main conclusion that it is impossible to create one universal forecast model for every farm. This means that each such facility requires an individual approach to obtain an effective forecast. The changing market environment requires further action and the development of new models suitable for the needs of the markets within a shorter time horizon.

DOI: 10.12736/issn.2330-3022.2020203

Received by the editor: 10.08.2020

Received in revised form: 9.09.2020

Accepted: 21.10.2020

Published online: 21.12.2020

Introduction

Owners of generating sources after their connection to the power grid become participants in the balancing market (RB), run by the transmission grid operator (TSO), which in Poland is Polskie Sieci Elektroenergetyczne SA. From that moment on, each balancing market's participant is obliged to forecast their own generating units' electricity output with a specified advance time [27, 28]. Forecasting electricity output by generators (including wind farms) is from the technical and commercial (balance of the demand and supply sides) perspectives essential to ensure continuous electricity supplies to end-users. Balancing mechanism unit owners must submit daily schedule notifications to

the TSO in advance. The TSO requires long-term (annual) and short-term (daily, hourly) forecasts. Notification of an entire daily-hourly schedule for the next trading day should be sent to the TSO at specified hours of the day. Those with wind units in their purchasing portfolio should prepare a daily-hourly forecast of their output to purchase or sell a certain amount of energy on The Polish Power Exchange (TGE). Companies trading in energy in the Exchange Market segment of the (i.e. TGE) purchase or sell electricity on the Day-Ahead Market (DAM) or the Intra-Day Market (IDM). The DAM is trading one day before the day when electricity is physically delivered, and the IDM is trading a few hours before its delivery [28]. An effective forecast will not only

maximise the cost of deviations on the BM but also increase the competitiveness of energy trading on the DAM and IDM.

The EU-adopted energy transformation policy has significantly influenced national regulations of the wind energy market in recent years [1]. As a result, in 2020, changes are planned to ease investment restrictions, in particular concerning the so-called distance act (10H), which stopped the dynamic development of this technology on land [2]. This approach will contribute to the construction of more wind farms, not only on land but also at sea. The greater the number of generation sources dependent on weather conditions, the more difficult their predictability and the greater the risk of trade imbalances in participants' purchasing portfolios. Any incorrect energy forecast, different from the actual output, will result in higher costs of participation in the BM, and in the long run may threaten a loss of financial liquidity, ownership takeover, or bankruptcy. Efficient electricity output forecasting allows trading companies, operators, and other entities to reduce the cost of their participation. The closer the electricity delivery date, the more accurate the forecast [24–27].

Wind farm output forecasting consists of two processes: forecasting the weather and estimating the generation capacity in each hour of the day corresponding to the weather forecast. The best weather forecasts for a specific wind farm (WF) are local numerical short-term forecasts based on the basic airflow physics principles [6, 14–16]. According to the literature [5, 18] and the author's own long-term professional experience, the longer the forecast's horizon, the greater its error. A forecast error results in a deviation, i.e. the difference between the hourly planned output and the actual electricity generated and supplied to the power grid. The input to the grid is the source output minus the transmission losses.

Specialist aids are used for forecasting [8, 9, 10]. The relevant literature is extensive and covers many electricity output forecasting methods: physical [4], statistical [3, 5], and behavioural [7, 16, 24, 26, 28]. Physical models are based on physical relationships between the weather conditions and the wind farm output. Statistical models directly describe statistical relationships between the wind farm output and the forecast weather parameters, the wind speed in particular. Behavioural models are based on artificial intelligence methods (e.g. artificial neural networks). Hybrid models combine physical, statistical, and behavioural methods. Moreover, there are several dedicated forecasting tools available commercially [19–22, 27]. Pragmatics prefers the hybrid approach [11, 13, 16–18]. To forecast wind farm output electricity neural models alone are also used.

Artificial neural networks (ANNs) can be an alternative to statistical or analytical models, in particular for determining power curves for systems distributed throughout a country. Each of these models has a different design, accuracy, computational complexity, and scope of application. An advantage of the neural and statistical models, as opposed to analytical (physical) models, is that they don't need complete information about the object model and its parameters. However, the statistical model requires a larger data set than ANN. Neural models require correct measurement data, proper structure and size of the network (selected experimentally), and an appropriate network training

method. ANN parameters are determined in the training process. The ultimate network training goal is to find the optimal weighting factors so that the model correctly reproduces the object's power curve.

The subject of the study was the properties of wind farm output forecasting models created with ANN that were subjected to various inputs [29]. From the many known ANN structures, Elman's Simple Recurrent Network was selected for this study. It was selected experimentally, by comparing the simulation results obtained with other neural structures, i.e. unidirectional single-layer network or unidirectional multi-layer network. The wind farm output forecast model was implemented in Matlab [17, 29]. The Elman network is a recurrent, multi-layer network. As part of the study, 11 ANN training methods [29] were tested, with two network training methods turning out to be best: Levenberg-Marquardt and Bayes. An advantage of the Bayes method is that it reduces the network training time with a large training sample and trains the network only until the best generalization is achieved. Thus, the training process does not seek to minimize the network error, but to maximize the generalization capabilities. This method, unlike the Levenberg-Marquardt method, prevents the network overtraining.

The model development was based on measurement data from a real WF in northern Poland. As the measurement data were made available by the farm owner as confidential, and only for this study, they have been standardized in the paper.

Description of the tested objects

The study was based on a limited number of measurement data. Fig. 1 shows the topology of the tested wind farm located in the northern part of Poland. The farm consists of 24 Vestas turbines (data from 5 randomly selected turbines were used for the study of this WF). For this WF the wind speed and direction data were obtained from anemometers installed on each nacelle (at the hub height 100 m above ground level). The output and wind conditions were measured every 10 minutes. The weather and

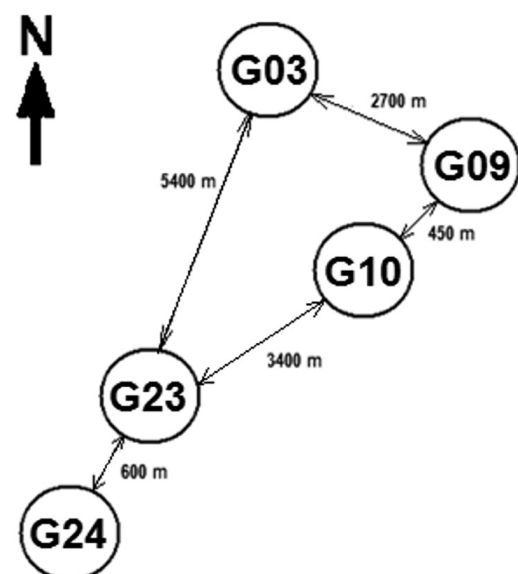


Fig. 1. Deployment of 5 of the 24 wind turbines of the extensive WF

output data were obtained with the SCADA system from various periods of the year.

All the WF turbines are of the same type. Wind speeds on an extensive wind farm can vary by as much as 30%, which the author experienced by analysing the measurement data [29] not only from this WF but also from many other operating wind farms (22 units) in the country during many years of his professional work. Analysis of the wind farm measurement data made it possible to observe the phenomena affecting the farm output. In the analysis of the wind farm output influencing factors, special attention was paid to the wind direction changes dynamics. When the wind direction changes, the wind speed changes, which translates into the rotational speed of the generator rotor. The wind speed has the greatest impact on the output (plays the most important role). Does the inclusion of additional factors in the model, e.g. wind direction, improve the wind farm output forecast accuracy?

Influence of factors on the output

Listed in Tab. 1 are coefficients of the correlation between the studied variables: wind speed measured on the nacelles (denoted as VwG03 ÷ VwG24), as well as the wind speed on the weather mast (denoted as VwM50) measured at 50 m above the ground, and the outputs of each turbine (denoted as Pc). The table also shows the correlation between the average wind speed (calculated for the entire wind farm and denoted as VwFarma) and the sum of outputs of the individual turbines and the farm's total output (the sum of WF outputs is denoted as PcFarma). The correlation results are marked in yellow (the speed for the entire WF is denoted as VwFarma and the sum of the WF outputs is denoted as PcFarma). After removing erroneous measurements from the data sets, as shown in Tab. 1, the correlation between variables becomes stronger. The erroneous measurements included zero values resulting from turning the turbine off. The correlation between these values is stronger when the wind speeds from all wind turbines are averaged.

Including wind direction in the electricity output forecast models can improve the forecast quality, but less than with a more accurate weather forecast. The difference in the generation outputs (between the most extreme summer and winter seasons) results is mainly due to the air density (in winter it is higher than in summer) and lower dynamics and frequency of wind changes. In general, the summer winds are weaker but more variable than in the winter. The analysis also shows that the details of the number of operable turbines on the farm, and regulatory constraints in the control systems are relevant and should be available. It was also noted that dynamic direction changes occur at low wind speeds (in summer), which means that in winter models the wind direction changes dynamics may be neglected. The author presented more observations in his doctoral dissertation [29].

For the forecast model development and verification measurement data on wind direction and speed, and output power are needed (this paper refers to hourly energy). With direct measurements at turbines, the entire object's characteristics can be identified, but due to the anemometer location on the nacelle behind the blades, the wind stream measurements do not reflect the actual wind conditions on the wind farm [29].

The operating points of the turbine and the farm lie at different points than the catalogue curve. Due to the high SCADA system purchase costs, not on all farms can Vw (wind speed) and Kw (wind direction) be measured directly on the nacelles, and the wind farm output is recorded only by the measurement and billing systems (meters) at the farm's interconnection with the power grid (MV/HV substation). Measurements for this WF were obtained from an external weather mast less than 10 km away from the WF. It should be taken into account that in the measurement data sets there may be data with an error resulting, for example, from the lack of periodic calibration of anemometers. These data may affect output forecast errors. Hence, the correctness of data for the training process should be evaluated first.

	VwG03	VwG09	VwG10	VwG23	VwG24	VwM50	PcG03	PcG09	PcG10	PcG23	PcG24	VwFarma	PcFarma
VwG03	1.000												
VwG09	0.943	1.000											
VwG10	0.938	0.949	1.000										
VwG23	0.910	0.953	0.938	1.000									
VwG24	0.917	0.949	0.955	0.978	1.000								
VwM50	0.923	0.917	0.936	0.894	0.914	1.000							
PcG03	0.976	0.928	0.932	0.897	0.910	0.924	1.000						
PcG09	0.915	0.974	0.931	0.927	0.927	0.908	0.936	1.000					
PcG10	0.924	0.933	0.980	0.912	0.933	0.933	0.948	0.948	1.000				
PcG23	0.901	0.940	0.925	0.969	0.952	0.896	0.917	0.953	0.931	1.000			
PcG24	0.913	0.938	0.944	0.949	0.972	0.919	0.933	0.953	0.955	0.976	1.000		
VwFarma	0.962	0.982	0.978	0.979	0.983	0.938	0.949	0.957	0.958	0.960	0.966	1.000	
PcFarma	0.946	0.964	0.964	0.952	0.960	0.937	0.967	0.980	0.978	0.977	0.986	0.980	1.000

Tab. 1. Analysis of correlation between the wind speed at the height of the wind turbine nacelles and the height of the weather mast after removal of erroneous measurements from the set (March)

Electricity output forecast model structure

Wind speed (VW) is the most important factor affecting the WF output, which is confirmed by the values in Tab. 1. Other factors influencing the output, i.e. strong wind gusts, air density, turbine availability, and terrain roughness, were omitted in the study due to difficulties in obtaining them. Wind direction (Kw) measurements were made directly on the nacelles, and the zero point calibration was not precisely assigned to each quarter, which was justified in the doctoral dissertation [29]. Hence, obscuring was not taken into account in the output models tested.

To answer the question of whether the inclusion of additional factors in the model, e.g. wind direction, improves the wind farm output forecast accuracy, two forecasting models were built with the Elman neural network structure. Partial recurrence of the Elman network differs from the other recurrent networks (i.e. Hopfield, Hamming, BAM, and ART networks) in that the feedback loop starts at the hidden layer output, not at the model output, and ends at the model input through the context layer in which there are unit delay operators of the propagated signal. Each hidden layer neuron has its counterpart in the contextual layer. Together with the network inputs, this layer is the input vector. When the state of one neuron changes, it affects the entire network through feedback. As a result, a transient state is obtained, which ends with a certain steady state (other than the previous state). To improve the neural network's accuracy, its weight and bias are modified by the algorithms: Levenberg-Marquardt's with variable metric (hereinafter denoted as PcTrainlm) and Levenberg-Marquardt's with built-in Bayesian regularization (Bayes network, hereinafter denoted as PcTrainbr).

Various neural models with different numbers of inputs and neurons in the hidden layer were tested experimentally. The models were implemented in Matlab. Two models were selected for further study: with one and two inputs. In the first

model, the average wind speed was entered at the input (Fig. 2), while in the second model the average wind speed (Vw) and direction (Kw) (Fig. 3). The models produce the tested object's power output (Pc).

Power model (Elman network) training and testing

The following sections describe the training and testing of the wind farm generation output forecast model with one input (Fig. 2) and two inputs (Fig. 3). The WF model consists of two different models, i.e. winter and summer models. The study used the measurement data available from the farm.

The single-input model: average wind speed

The subject of the study was a wind farm model with one input: wind speed. The number of neurons was selected by trial and error, guided by the training error. The number of neurons in the hidden layer was set to 15. The study aimed to check whether the electricity output for the entire facility can be forecast based on the average wind speed for a WF with an extensive structure. The test was performed for the wind speed average from all 5 turbines and the wind speed from the weather mast. The training value was the sum of electricity outputs of the 5 turbines in each hour of the day.

Fig. 4 and 5 show the results of network training with the Levenberg-Marquardt method (PcTrainlm) and the Levenberg-Marquardt method with built-in Bayesian regularization (PcTrainbr). Fig. 6a shows the training process from the summer period and the effects of network training by the PcTrainlm and PcTrainbr methods. With only the wind speed for the object known, it is necessary to agree on the height for which this value was prepared, and if necessary, to extrapolate the forecast to the expected height of the wind turbines.

The model with two inputs: average wind speed and wind direction

The subject of the study is a wind farm model with two inputs: wind speed and wind direction. The number of neurons was selected by the same method as in the single-input model. The number of neurons in the hidden layer was set to 15. This paper aims to assess the effectiveness of the farm output forecast model, whether the inclusion of additional factors in it, such as wind direction, will improve the output forecast accuracy. The author, analysing the wind direction measurement data, noticed that the direction also affects the farm output, but to a lesser extent than the wind speed. He also noticed that the wind direction measurement on the nacelles is not exactly consistent with the quarters, which makes it difficult to use this value in forecasting models [29]. In this paper, an attempt is made to develop and test a model that includes wind direction. The tests of the wind farm model show that the wind direction inclusion, especially with an uncertain measurement method (lack of proper calibration with respect to the quarters), may result in greater errors already at the network training stage than using a more reliable and relevant wind speed.




Fig. 2. WF generation output model with one input: wind speed




Fig. 3. WF generation output model with two inputs: wind speed and wind direction

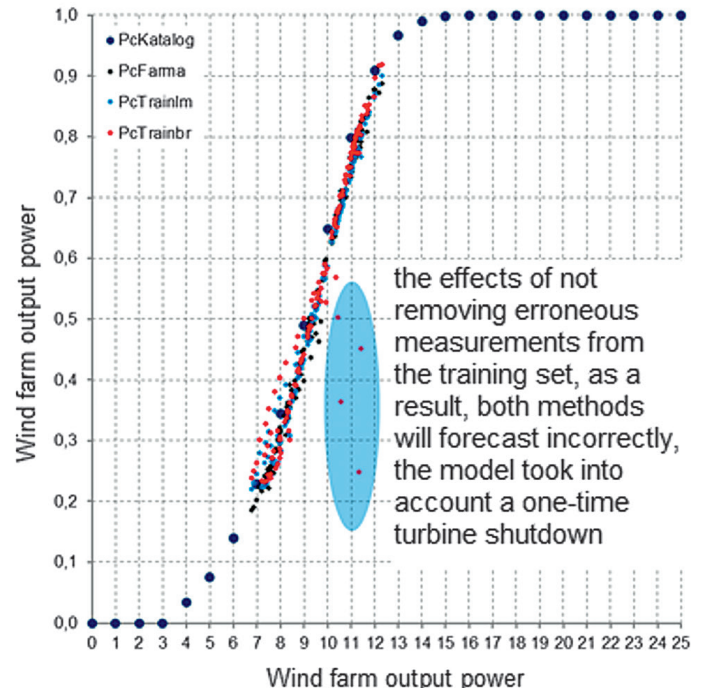
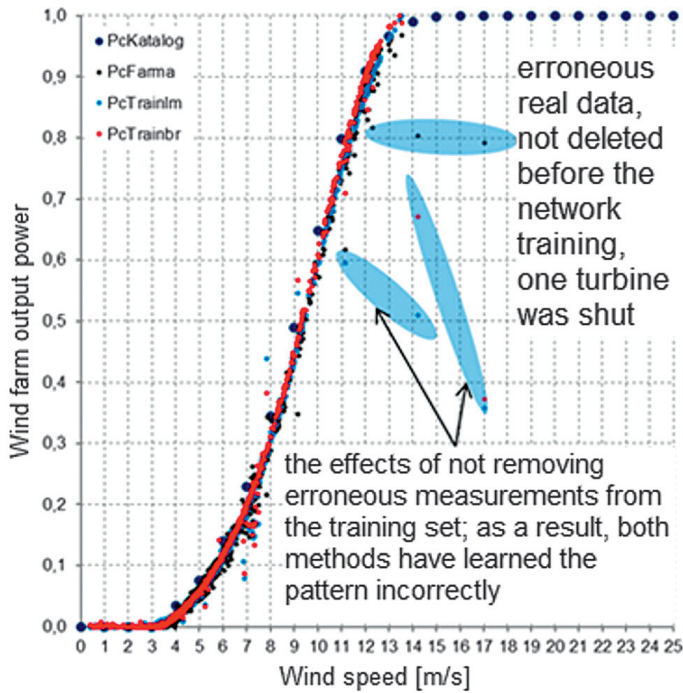


Fig. 4. WF power output as a function of wind speed – the result of the network training in the summer

Fig. 5. WF power output as a function of wind speed – the result of the network testing in the summer

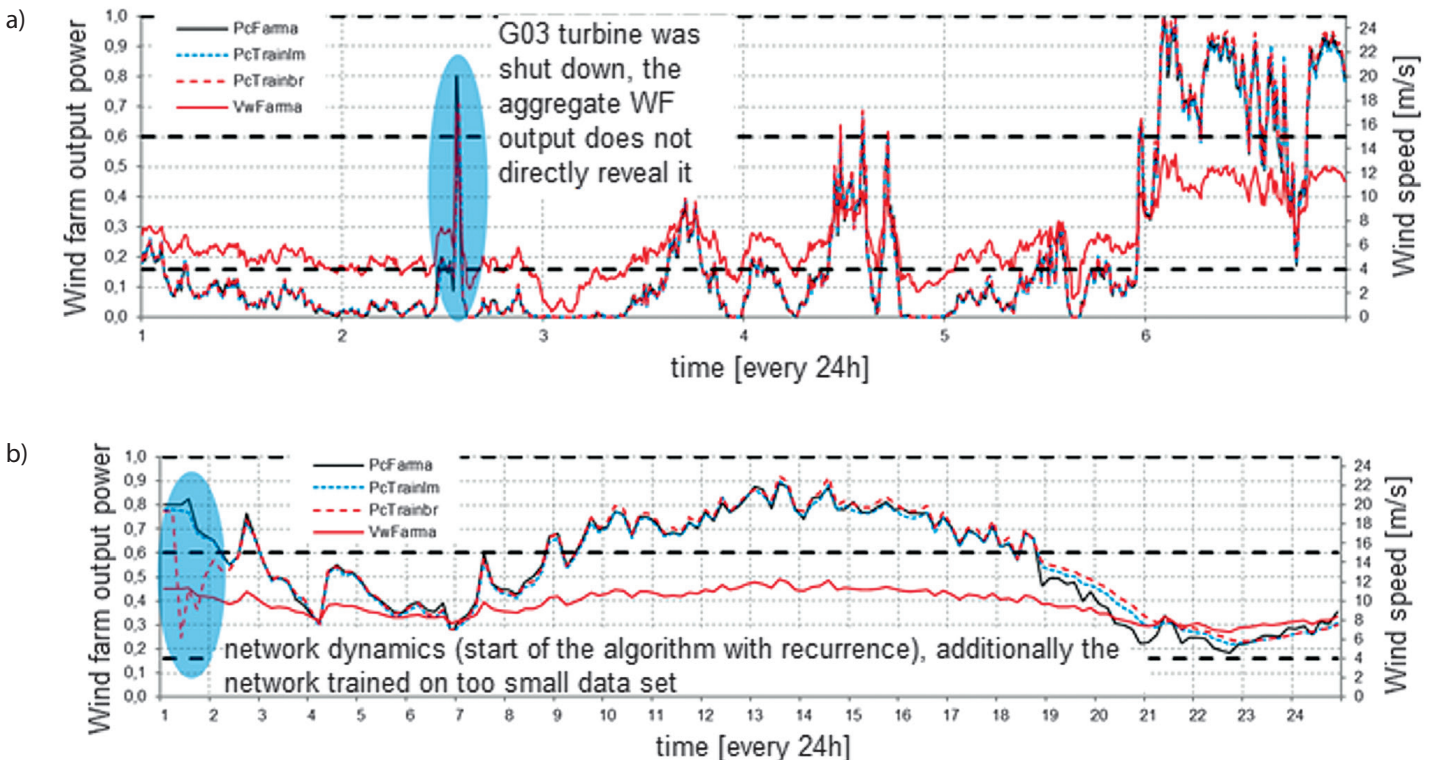


Fig. 6. WF generation output: (a) network training (6 days) and (b) model testing (1 day) in the summer

Power model properties testing

The dynamic properties of the single-input neural model alone are shown below to determine the power curve reproduced for specific wind forces. The model was tested under specific inputs, i.e. wind speed sequences. Fig. 7–10 show the test results of the

model trained by two methods (PcTrainlm and PcTrainbr). As part of the study, the responses of both networks to a predetermined input (variable wind speed for summer and winter) were examined. The input type is shown in Fig. 8 while in Fig. 9 responses to the inputs are shown. The analysis showed that the model responses

vary depending on the input type. A reason for it is that both power models are dynamic networks (with partial recurrence). In the figures below the changes are marked with blue areas. The graph shows that the greater the wind speed changes dynamics, the greater the qualitative changes in the response (Fig. 8), which also translates into different generation outputs. It is obvious that the network generates values lower than would result from the catalog values (because there are transmission losses, the effect of obscuration, etc.), but other causes are also evident, as in Fig. 8, which shows the difference between the outputs forecast by the model trained on winter and summer data. The difference is due to the lower air density in summer than in winter, and also to the greater wind direction change dynamics.

Also observed (Fig. 10) was the model trained on summer data (PcTrainIm Summer) is more resistant to rapid wind speed changes than the model trained on winter data (PcTrainIm Winter). A short-term sudden wind speed change (or incorrectly entered data) may cause a long-term disturbance in the network operation. Fortunately, the model is used for prediction, and the forecast wind does not change so rapidly. Wind speed in summer changes more often than in winter, hence the PcTrainIm Summer model has the network weighting factors optimally adjusted for changing wind conditions. Both neural models should be used interchangeably depending on the season.

Test results – comparison of two WF power output models

The author's own observations show [29] that the power output forecast error arises from errors in the weather forecast, and the wind farm power output model itself. To select the correct prediction model, a specific error measure must be adopted. Four quality indicators have been proposed to enable model selection. Fig. 11–14 show the quality indices calculated for the model with one input (Fig. 11–12) and two inputs (Fig. 13–14) that allow selecting a prediction model from a range of different methods. To assess the model quality, the WF output prediction obtained from the model and the actual generation output were used. Four criteria were selected to assess the forecast quality, i.e. the sum of energy outputs in a specific period [MWh], absolute error, the sum of the forecast deviations from the actual outputs, and the variation coefficient (dynamics). The network training and testing results are presented in Tab. 2 and 3. The variation coefficient represents the power output variability dynamics, i.e. the extreme values distant from the average. The higher the factor, the greater the power output dynamics. The wind farm output forecasting model with a low variation coefficient increases the forecast efficiency.

Selection of the effective WF power output model

The tables below present the indicators calculated for two WF generation output model configurations: with one input and with two inputs. The results of the first model are denoted in Tab. 2 and 3 as VwFarma (wind speed model), and the other as VwKwFarma (wind speed and wind direction model). Listed in Tab. 2 are the model training quality indicators based on the data

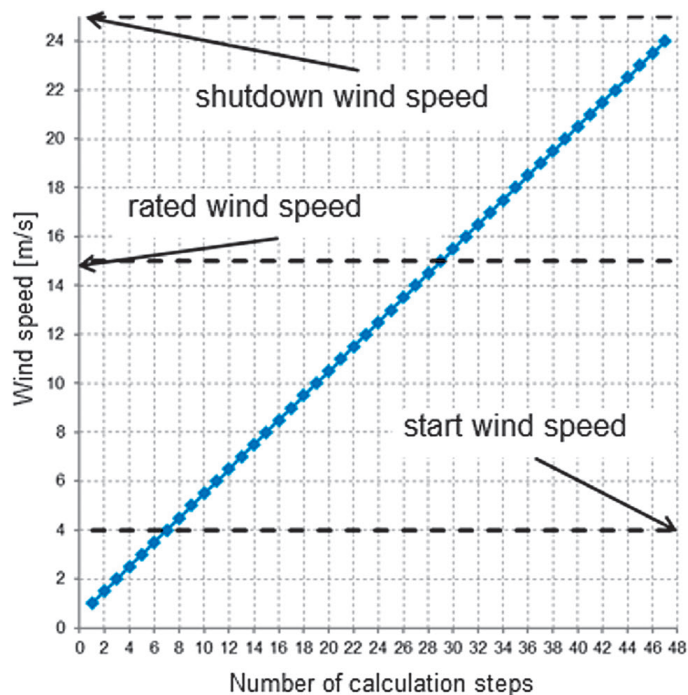


Fig. 7. input controlled by linearly increasing wind speed

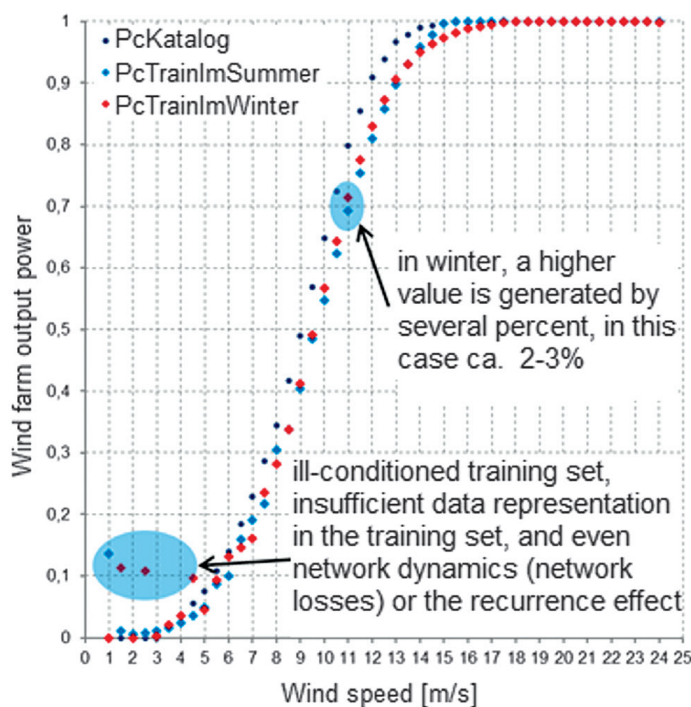


Fig. 8. Response of WF models as a wind speed function

from 6 days (data sample of $N = 862$ measurements), i.e. the sum of energy outputs, from which it can be found out if the model forecasts the electricity outputs close to the actual sum in any period; absolute error of the total generation output model; the sum of the output deviations from the difference module to find out how large the difference volume is in relation to the actual generation output, and the variation coefficient of the model's generation output forecast, which describes the generation

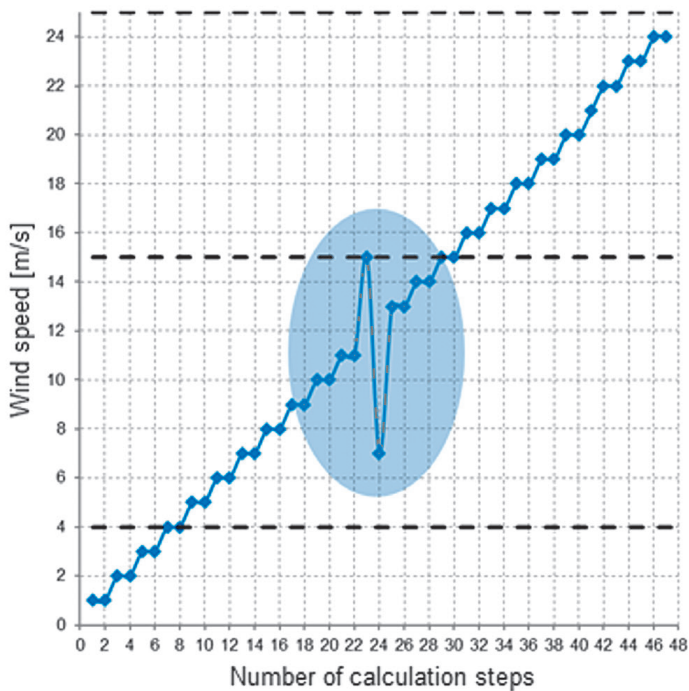


Fig. 9. Input controlled by increasing wind speed

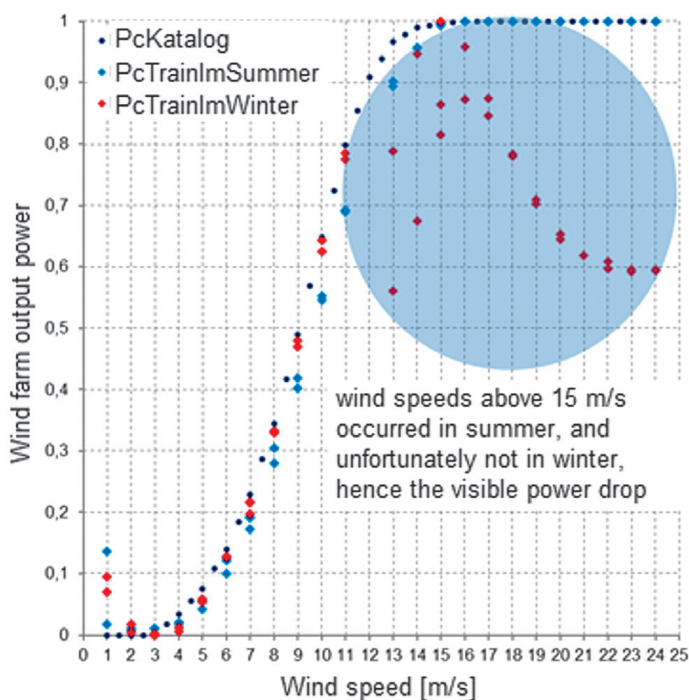


Fig. 10. Response of WF models as a wind speed function

output variability dynamics in the analysed period. The model was trained on summer and winter data.

The difference in energy volume (absolute error) for the single-input PcTrainIm trained model is 0.5450 and the PcTrainbr trained model is 0.0050. With these two values, it is still difficult to decide which model is better. Therefore, the sum of the energy deviations is calculated (Fig. 12), and then the generation output variation coefficient (Fig. 14). The training methods are compared,

and it is already known which model is better. In this test case, the PcTrainbr trained power output model is better. The same is done with the other model configurations and the examined periods. Defining other parameters, i.e. arithmetic mean, it is not advisable at this stage, because this parameter is used to calculate the standard deviation, so it has already been considered. Listed in Tab. 3 are the quality results of the tested model for 1 day (data sample of $N = 144$ measurements). The model was tested on summer and winter data. Based on the variation coefficient, it can be concluded that the model including the wind speed only (VwFarma) is more effective than that with the wind direction. What is reflected in the model testing results in Tab. 3. Power output prediction differences between the models result primarily from the network training method.

One universal wind farm output model, which is a good estimator for all wind conditions, cannot be developed. This is confirmed by the difference between the errors of both models in relation to the actual generation output. The study shows that the network can be trained to learn the actual wind farm conditions for all seasons. The testing phase shows that methods that work better in summer do worse in winter, and vice versa. The neural network is a good estimator of the WF power curve.

Summary

This paper aims to evaluate the effectiveness of the wind farm output forecast model, i.e. the output modelling for specific weather conditions. The model represents the characteristics of a particular WF. As part of the task, the measurement data obtained from an actual wind farm were thoroughly analysed, with particular attention to the impact of weather conditions variability on the generation output and wind conditions occurring in such facilities.

As a result of this analysis, it was determined what affects the farm output, and which impacts are so significant that must be included in the model. Two input variables were chosen: wind speed as the basic input and additionally wind direction. The analysis of measurement data shows that each WF features different terrain conditions and the model's structure must be able to represent them. This was the main reason for choosing the neural model. For the model implementation, the Elman recurrent network was selected to be trained by the Levenberg-Marquardt with variable metric and Levenberg-Marquardt with built-in Bayesian regularization methods. This choice was preceded by extensive simulation studies of various network structures trained by various methods. A methodology was proposed for selecting the effective prognostic model using selected quality indicators, i.e. sum of generation outputs, absolute error, the sum of generation output deviations, and generation output variation coefficient.

The factors that affect the farm output described in the paper should be considered in forecasting models at various stages of the forecasting process. The WF generation output depends not only on the weather conditions but also on the method of operation and control of this type of facility, as well as its terrain conditions and location. By analysing the measurement data, some characteristic relationships can be identified. The analyses

Sample	Season and factors	VwFarma		VwKwFarma	
862	Training method	summer	winter	summer	winter
Total power output [MW]	PcFarma (Pc)	266.7010	799.2590	266.7010	799.2590
	PcTrainlm	266.1560	792.4970	266.9650	799.4900
	PcTrainbr	266.6960	799.2780	266.2420	803.3350
Absolute error [MWh]	PcFarma (Pc)	0.00000	0.00000	0.00000	0.00000
	PcTrainlm	0.54482	6.76226	0.26389	0.23053
	PcTrainbr	0.00495	0.01867	0.45883	4.07575
Sum of power output deviations [MW]	PcFarma (Pc)	0.0000	0.0000	0.0000	0.0000
	PcTrainlm	9.2750	18.6580	11.0340	17.6340
	PcTrainbr	8.2870	15.2990	62.0780	126.5920
Variation coefficient [%]	PcFarma (Pc)	1.34700	0.50500	1.34700	0.50500
	PcTrainlm	1.34800	0.51500	1.34700	0.50200
	PcTrainbr	1.34400	0.50400	1.30400	0.41600

Tab. 2. Quality of the trained neural models at the average wind speed for the entire wind farm (sample of 862 measurements – 6 days)

Sample	Season and factors	VwFarma		VwKwFarma	
144	Training method	summer	winter	summer	winter
Sum of generation outputs [MW]	PcFarma (Pc)	104.3280	49.5640	104.3280	49.5640
	PcTrainlm	102.4930	49.9320	102.9300	49.7800
	PcTrainbr	100.1900	48.8130	89.1240	67.9830
Absolute error [MWh]	PcFarma (Pc)	0.00000	0.00000	0.00000	0.00000
	PcTrainlm	1.83533	0.36820	1.39775	0.21629
	PcTrainbr	4.13847	0.75099	15.20446	18.41915
Sum of power output deviations [MW]	PcFarma (Pc)	0.0000	0.0000	0.0000	0.0000
	PcTrainlm	2.4330	7.7480	2.1500	4.2120
	PcTrainbr	4.8470	4.9920	16.5150	23.6310
Variation coefficient [%]	PcFarma (Pc)	0.25800	1.13800	0.25800	1.13800
	PcTrainlm	0.26500	1.09100	0.26400	1.10800
	PcTrainbr	0.28300	1.14500	0.22700	0.68300

Tab. 3. Quality of the tested neural models at the average wind speed for the entire wind farm (sample of 144 measurements – 1 day)

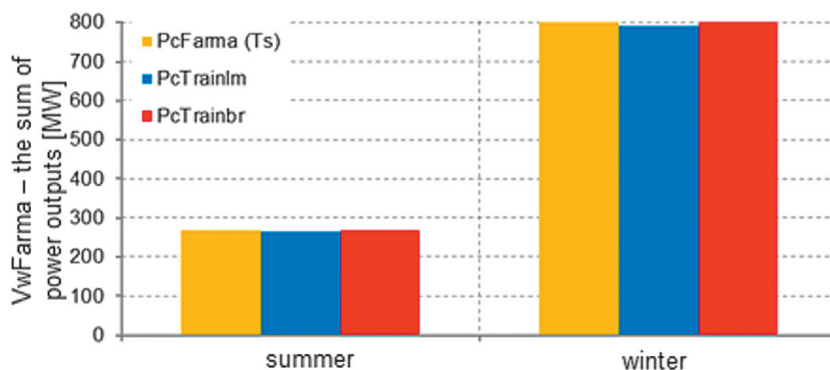


Fig. 11. Sum of the generation outputs of both neural models together with the actual output in various seasons of the year (data from Tab. 2, single input)




Fig. 12. Sum of deviations from the average generation output at different times of the year (data from Tab. 2, single input)




Fig. 13. Absolute error for various seasons (data from Tab. 2, single input)




Fig. 14. Generation output change dynamics for various seasons (data from Tab. 2, single input)

showed that based on actual weather data, i.e. the wind speed and direction, air density, rainfall for local conditions, and on the generation outputs from individual turbines and the meter at the MV/HV substation, a successful forecasting model can be developed. An open issue is the model structure: deterministic – based on physical phenomena and analytical dependencies vs. behavioural model developed of a neural network.

The simulation results shown in Fig. 7–10 and obtained for WF generation output forecast models (for various seasons: summer and winter) indicate that neural networks can generate forecasts similar to the actual output and therefore can constitute an alternative method of electricity generation forecasting. Deviations of the forecast outputs from the actual ones may be due to the wind farm model properties. As noted, the WF models that perform

better in the summer do worse in the winter, and vice versa. Detailed results of the properties tests are shown in Fig. 8 and 10, which showed that the neural network, despite a limited set of historical measurement data, can reproduce power curves similar to the catalogue curves, taking into account the object's characteristics. Given the choice of an analytical, statistical, or neural model, the qualitative coefficients should definitely be analysed, and then the most appropriate model selected. A testing phase should always be carried out before making the final selection of a model to obtain a higher probability of forecast accuracy. A hybrid model is also worth considering. The study shows that a network with an appropriate structure is a good estimate of the farm generation output and can be used alternatively when developing hybrid models. The WF power output model should be matched to the farm's characteristics. The WF output is forecast best in the short term, based on data from weather masts located in the farm's proximity. This distance should not exceed 10 km. The weather forecast based on measurement data from a local weather mast allows improving the generation output forecast accuracy, and thus avoiding a significant deviation on the Balancing Market.

The variety of wind farm structures and the multitude of their output affecting factors make the development of one universal forecast model difficult. Hence, the best models on the market are hybrid models (made up of several different models), which also use behavioural models (e.g. artificial neural networks). Choosing the right model takes time and money. Forecasting the farm generation output without operator experience may be burdened with a large error and may turn out to be costly participation in the Balancing Market, therefore, to reduce the risk, it is worth spending more time at the measurement data analysis stage.

The author has exhaustively researched the subject for 10 years, reaching the main conclusion that it is impossible to create one universal model of generation output forecast the same for every wind farm. This has been confirmed by various forecasts procured for selected wind farms using neural models for the needs of wholesale trade in a trading company. This means that each facility of this type requires an individual approach to forecasting to effectively forecast its generation output.

The above conclusions do not allow the author to further study the daily-hourly forecasts for the Day-Ahead Market. Moreover, the changing market environment requires further action and the development of new prognostic models suitable for the needs of the markets in a shorter (hour, minute) time horizon for both markets, i.e. Intra-Day Market and Balancing Market. According to the notice published on the TSO website [30], from 2021 the Balancing Market will undergo thorough changes in the rules of its operation, which will significantly affect the participation costs.

REFERENCES

1. Directive 2009/28/EC of the European Parliament and of the Council of 23 April 2009 on the promotion of the use of energy from renewable sources and amending and subsequently repealing Directives 2001/77/EC and 2003/30/EC, OJ L 140, 5.6.2009, pp. 16–62

2. Rząd pracuje nad zmianą zasady 10H. Co zaproponuje? [The government is working on amending the 10H rule. What will it propose?] [online], <https://www.gramwzielone.pl/energia-wiatrowa/103511/rzad-pracuje-nad-zmiana-zasady-10h-co-zaproponuje> [access: 30.07.2020].
3. Flores J.J., Graff M., Rodriguez H., Evolutive design of ARMA and ANN models for time series forecasting, *Renewable Energy*, Vol. 44, 2012, pp. 225–230.
4. Soman S.S. et al., A review of wind power and wind speed forecasting methods with different time horizons, North American Power Symposium (NAPS), 2010, IEEE Xplore [online], https://www.researchgate.net/publication/224188805_A_review_of_wind_power_and_wind_speed_forecasting_methods_with_different_time_horizons [access: 28.10.2020].
5. Jursa R., Wind power prediction with different artificial intelligence models [online], https://www.researchgate.net/publication/228964192_Wind_power_prediction_with_different_artificial_intelligence_models [access: 28.10.2020].
6. Sveinbjornsson S., Analysis of WasP (Wind Atlas Analysis and Application Program) in complex topographical conditions using measured production from a large scale wind farm, A thesis submitted in partial fulfillment of the requirements for the degree, Department of Civil and Environmental Engineering, University of Washington 2013.
7. Zeng J., Qiao W., Support Vector Machine-Based Short-Term Wind Power Forecasting [online], <https://core.ac.uk/download/pdf/189669024.pdf> [access: 28.10.2020].
8. Wind Energy Division, Risø DTU, www.wasp.dk, <http://www.risoe.dtu.dk>.
9. EMD International A/S [online], www.emd.dk/WindPRO [access: 28.10.2020].
10. RETScreen International [online], www.retscreen.net [access: 28.10.2020].
11. Rubanowicz T., Metody predykcji produkcji mocy parku wiatrowego [Wind farm output prediction methods] *Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej*, No. 25, 2008, pp. 145–149.
12. Rubanowicz T., Bogalecka E., Ocena charakterystyki mocy parku wiatrowego [Wind farm power characteristics evaluation], PES-7, VII Ogólnopolska Konferencja Naukowo-Techniczna PTETiS, Kościelisko 22–26.06.2009.
13. Rubanowicz T., Bogalecka E., Analiza charakterystyk parku wiatrowego [Wind farm characteristics analysis], *Wiadomości Elektrotechniczne*, No. 2, 2010, pp. 15–20.
14. Rubanowicz T., Bogalecka E., Neuronowy model mocy farmy wiatrowej [Neural model of wind farm power], *Mechanik*, No. 7, 2010, pp. 579–586.
15. Rubanowicz T., Bogalecka E., Modele farmy wiatrowej na potrzeby prognozowania mocy [Wind farm models for power output forecasting], X Krajowa Konferencja Naukowa SENE, Łódź 2011.
16. Rubanowicz T., Bogalecka E., Model fizyczny – czy neuronowy? – narzędzia do predykcji mocy wytwarzanej przez elektrownie wiatrowe [Physical – or neural model? – tools for wind farm output prediction], XVI Międzynarodowa Szkoła Komputerowego Wspomagania Projektowania, Wytwarzania i Eksploatacji, Jurata 2012.
17. Rubanowicz T., Budowa modelu prognostycznego farmy wiatrowej w środowisku MATLAB [Building a wind farm forecast model in the MATLAB environment], XXII Seminarium Zastosowanie Komputerów w Nauce i Technice, Oddział Gdański PTETiS, Gdańsk 2012.
18. Landberg L., Short-term prediction of the power production from wind farms, *Journal of Wind Engineering and Industrial Aerodynamics*, Vol. 80, No. 1–2, 1999, pp. 207–220.
19. Barbero A., Lopez J., Dorronsoro J.R., Kernel methods for wide area wind power forecasting [online], <https://repositorio.uam.es/handle/10486/665710> [access: 28.10.2020].
20. Nielsen T.S., Online prediction and control in nonlinear stochastic systems, Technical University of Denmark, Ph.D. Thesis No. 84, 2002 [online], <http://www2.imm.dtu.dk/pubdb/edoc/imm792.pdf> [access: 30.10.2020].
21. Saint-Drenan Y-M., Wind power predictions analysis, part 2, Economical analysis, ECN-I-02-011 (2002).
22. Rubanowicz T., Bogalecka E., Warunki wiatrowe na rozległej farmie wiatrowej [Wind conditions on an extensive wind farm], *Mechanik*, No. 7, 2011, pp. 29–36.
23. Monteiro C. et al., Wind power forecasting: State-of-the-Art 2009, Decision and Information Sciences Division, ANL/DIS-10-1, Argonne National Laboratory 2009.
24. Holttinen H., Optimal electricity market for wind power, *Energy Policy*, Vol. 33, 2005, pp. 2052–2063.
25. Waldl I., Kariniotakis G.N., The Anemos wind power forecasting platform technology – techniques and experiences, EWEC 2006.
26. Parkers J., Tindal A., Forecasting Short Term Wind Farm Production in Complex Terrain, Garrard Hassan and Partners Ltd [online], www.gl-garradhassan.com [access: 30.07.2020].
27. Lichota A., Prognozowanie krótkoterminowe na lokalnym rynku energii elektrycznej [Short-term forecasting on the local electricity market], doctoral dissertation, AGH University of Science and Technology, Kraków 2006.
28. Centrum Informacji o Rynku Energii [online], www.cire.pl [access: 30.07.2020].
29. Rubanowicz T., Prognozowanie mocy wytwórczej farmy wiatrowej [Forecasting wind farm generation capacity], doctoral dissertation, Gdańsk University of Technology, Gdańsk 2019.
30. TSO notice of 21 May 2020 [online] <https://www.pse.pl/-/spotkanie-informacyjne-dotyczace-zmian-zasad-funkcjonowania-ryнку-bilansujacego> [access: 30.07.2020].

Tomaz Rubanowicz

Energa Obrót SA of ORLEN Group

e-mail: tomruban@gmail.com

A graduate of the Military University of Technology in mechatronics and doctoral studies at Gdańsk University of Technology in automation, electronics, and electrical engineering. Author and co-author of numerous publications, a participant of industry conferences. His interests include the application of artificial intelligence methods, renewable energy sources, energy efficiency.

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

PL

Wybrane narzędzia do prognozowania dobowo-godzinowego energii elektrycznej wytwarzanej przez elektrownie wiatrowe na potrzeby rynku hurtowego

Autor

Tomasz Rubanowicz

Słowa kluczowe

prognozowanie krótkoterminowe, elektrownie wiatrowe, sztuczne sieci neuronowe

Streszczenie

Właściciele źródeł wytwórczych po przyłączeniu do sieci elektroenergetycznej stają się uczestnikami rynku energii elektrycznej, w tym rynku bilansującego. Od tego momentu każdy uczestnik zobowiązany jest do prognozowania produkcji energii własnych jednostek wytwórczych z określonym wyprzedzeniem czasowym. Przyjęta polityka transformacji energetycznej znosi ograniczenia inwestycyjne, w szczególności w zakresie tzw. ustawy odległościowej (10H), która wstrzymała dynamiczny rozwój tej technologii na lądzie. Takie podejście przyczyni się do budowy kolejnych elektrowni wiatrowych. Im większa będzie liczba źródeł wytwórczych, których produkcja zależy od warunków pogodowych, tym trudniejsza będzie ich przewidywalność i większe ryzyko niezbilansowania handlowego portfeli zakupowych uczestników. Każda błędna prognoza energii, różniąca się od rzeczywistej produkcji, będzie skutkowałą większymi kosztami uczestnictwa w rynku. Skuteczne prognozowanie produkcji energii umożliwia przedsiębiorstwom redukcję kosztów ich uczestnictwa. Artykuł prezentuje metodę prognozowania energii farmy wiatrowej za pomocą sztucznych sieci neuronowych, które mogą stanowić alternatywne narzędzie względem modeli analitycznych i statystycznych. Celem artykułu była ocena skuteczności modelu prognozy energii farmy, czyli modelu odtwarzającego moc farmy dla określonych warunków meteorologicznych. W artykule przedstawiono czynniki wpływające na moc farmy, które należy uwzględnić w modelu, a także wykazano, że sieć neuronowa potrafi odtworzyć krzywe mocy farmy zbliżone do krzywych katalogowych z uwzględnieniem cech charakterystycznych obiektu. Autor przez 10 lat wyczerpał temat, dochodząc do głównego wniosku, że nie można stworzyć jednego uniwersalnego modelu prognozy dla każdej farmy. Oznacza to, że każdy tego typu obiekt wymaga indywidualnego podejścia, aby uzyskać skuteczną prognozę. Zmieniające się otoczenie rynkowe wymaga dalszych działań i opracowania nowych modeli sprawdzających się w krótszym horyzoncie czasowym na potrzeby rynków.

Data wpływu do redakcji: 10.08.2020

Data wpływu do redakcji po recenzjach: 9.09.2020

Data akceptacji artykułu: 21.10.2020

Data publikacji online: 21.12.2020

Wprowadzenie

Właściciele źródeł wytwórczych po przyłączeniu do sieci elektroenergetycznej stają się uczestnikami rynku bilansującego (RB), prowadzonego przez operatora sieci przesyłowej, którego rolę pełnią Polskie Sieci Elektroenergetyczne SA (OSP). Od tego momentu każdy uczestnik RB zobowiązany jest do prognozowania produkcji energii elektrycznej własnych jednostek wytwórczych z określonym wyprzedzeniem czasowym [27, 28]. Prognozowanie produkcji energii elektrycznej przez wytwórców (w tym jednostek wiatrowych) jest niezbędną czynnością w zapewnieniu ciągłych dostaw energii elektrycznej (EE) odbiorcom

końcowym od strony technicznej, jak i handlowej (bilans strony popytowej i podaźowej). Mając własną jednostkę bilansowania handlowego niezbędne jest dokonywanie codziennych zgłoszeń graficznych do OSP z wyprzedzeniem czasowym. OSP wymaga prognoz długoterminowych (rocznych), jak i krótkoterminowych (dobowych, godzinowych). Zgłoszenie całego grafiku dobowo-godzinowego na kolejną dobę handlową należy wysłać do OSP o określonych godzinach doby. Mając jednostki wiatrowe w portfelu zakupowym, należy przygotować prognozę dobowo-godzinową produkcji energii elektrycznej tych źródeł na potrzeby zakupu lub sprzedaży określonej ilości energii

na Towarowej Giełdzie Energii (TGE). Spółki handlujące energią w segmencie Rynku Giełdowego (tzn. TGE) dokonują zakupu lub sprzedaży energii elektrycznej w ramach Rynku Dnia Następnego (RDN) lub Rynku Dnia Bieżącego (RDB). RDN prowadzony jest na dzień przed dobą, w której następuje fizyczna dostawa energii elektrycznej, a RDB na kilka godzin przed jej dostawą [28]. Skuteczna prognoza pozwoli nie tylko maksymalnie zredukować koszty odchyień na RB, ale także zwiększy konkurencyjność handlu energią na RDN i RDB. Przyjęta polityka transformacji energetycznej Unii Europejskiej w ostatnich latach znacząco wpłynęła na krajowe

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

PL

regulacje rynku energetyki wiatrowej [1]. W efekcie w 2020 roku planowane są zmiany łagodzące ograniczenia inwestycyjne, w szczególności w zakresie tzw. ustawy odległościowej (10H), która wstrzymała dynamiczny rozwój tej technologii na lądzie [2]. Takie podejście przyczyni się do budowy kolejnych elektrowni wiatrowych, nie tylko lądowych, ale również morskich. Im większa będzie liczba źródeł wytwórczych, których produkcja zależy od warunków pogodowych, tym trudniejsza będzie ich przewidywalność i większe ryzyko niezbilansowania handlowego portfeli zakupowych uczestników. Każda błędna prognoza energii, różniąca się od rzeczywistej produkcji, będzie skutkowała większymi kosztami uczestnictwa w RB, a w dłuższej perspektywie może grozić utratą płynności finansowej, przejęciem własnościowym lub bankructwem przedsiębiorstwa. Skuteczne prognozowanie produkcji energii elektrycznej umożliwia przedsiębiorstwom obrotu, operatorom i innym podmiotom redukcję kosztów ich uczestnictwa. Im bliżej terminu dostawy energii elektrycznej, tym prognoza dokładniejsza [24–27].

Prognozowanie energii elektrycznej farm wiatrowych to dwa procesy: prognozowanie pogody i estymacja mocy wytwórczej w każdej godzinie doby odpowiadająca prognozie pogody. Najlepszymi prognozami pogody dla wybranej farmy wiatrowej (FW) są lokalne numeryczne prognozy krótkoterminowe, które oparte są na podstawowych zasadach fizyki przepływu powietrza [6, 14–16]. Jak wynika z literatury [5, 18] i własnych wieloletnich doświadczeń zawodowych autora, im dłuższy horyzont prognozowania, tym większy jest jej błąd. Skutkiem błędu prognozy jest odchylenie, czyli różnica między planowaną godzinową energią elektryczną a rzeczywiście wyprodukowaną (wykonaniem) i wprowadzoną do sieci elektroenergetycznej. Wprowadzona energia jest pomniejszona o straty przesyłowe.

Do prognozowania wykorzystuje się specjalistyczne narzędzia wspomagające [8, 9, 10]. Literatura tematu jest obszerna i opisywanych jest wiele metod prognozowania produkcji energii elektrycznej: fizyczne [4], statystyczne [3, 5] czy też behawioralne [7, 16, 24, 26, 28]. Modele fizyczne opierają się na zależnościach fizycznych między warunkami meteorologicznymi a produkcją energii

farmy wiatrowej. Modele statystyczne opisują bezpośrednio zależności statystyczne między produkcją energii farmy wiatrowej a prognozowanymi wielkościami meteorologicznymi, w szczególności prędkości wiatru. Modele behawioralne – oparte są na metodach sztucznej inteligencji (np. sztucznych sieciach neuronowych). Modele hybrydowe są połączeniem metod fizycznych, statystycznych i behawioralnych. Ponadto na rynku funkcjonuje kilka dedykowanych narzędzi prognostycznych udostępnianych komercyjnie [19–22, 27]. Pragmatyka preferuje podejście hybrydowe [11, 13, 16–18]. Do prognozowania energii elektrycznej farm wiatrowych wykorzystuje się również same modele neuronowe.

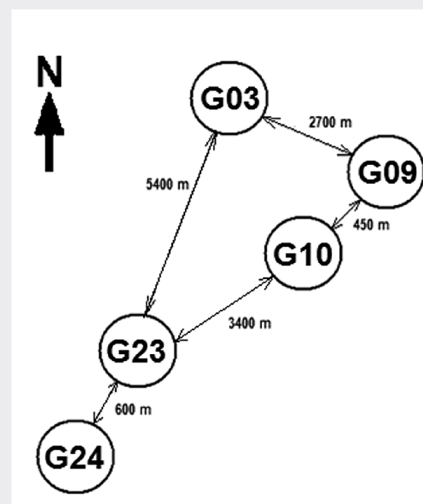
Sztuczne sieci neuronowe (SSN) mogą stanowić alternatywę dla modeli statystycznych czy analitycznych, w szczególności przy wyznaczaniu krzywych mocy dla instalacji o rozproszonej strukturze na terenie kraju. Każdy z tych modeli ma inną konstrukcję, dokładność, złożoność obliczeniową i zakres stosowania. Zaletą stosowania modeli neuronowych i statystycznych, w przeciwieństwie do modeli analitycznych (fizycznych), jest brak konieczności posiadania pełnej informacji o modelu obiektu oraz jego parametrach. Model statystyczny wymaga jednak bardziej licznych zbiorów danych niż SSN. Modele neuronowe wymagają poprawnych danych pomiarowych, właściwej struktury i rozmiaru sieci (dobranej metodą doświadczalną) oraz odpowiedniej metody uczenia sieci. Parametry SSN ustalane są w procesie uczenia. Celem końcowym uczenia sieci jest znalezienie optymalnych współczynników wagowych, tak by model prawidłowo odtwarzał krzywą mocy obiektu.

Przedmiotem badania były właściwości modeli prognozowania energii elektrycznej FW stworzone za pomocą SSN, które poddano różnym wymuszeniom [29]. Z wielu znanych struktur SSN do badań wybrano sieć rekurencyjną Elmana (ang. Simple Recurrent Networks). Wyboru dokonano doświadczalnie, porównując ze sobą wyniki symulacji uzyskane za pomocą innych struktur neuronowych, tj. sieci jednokierunkowej jednowarstwowej czy też sieci jednokierunkowej wielowarstwowej. Model prognozy energii elektrycznej FW zaimplementowano w programie Matlab [17, 29]. Sieć Elmana jest siecią rekurencyjną, wielowarstwową.

W ramach badań sprawdzono 11 metod uczenia SSN [29], a najlepszymi metodami uczenia sieci okazały się dwie metody, tj.: Levenberga-Marquardta oraz Bayesa. Jedną z zalet metody Bayesa jest to, że skraca czas uczenia sieci przy dużej próbce uczącej i uczy sieć jedynie do momentu osiągnięcia najlepszej generalizacji. W procesie uczenia nie dąży więc do minimalizacji błędu sieci, a do maksymalizacji zdolności generalizacyjnych. Metoda ta zapobiega przeuczeniu sieci w przeciwieństwie do metody Levenberga-Marquardta. Podstawą do budowy modeli były dane pomiarowe funkcjonującej FW na terenie kraju (na północy). Ponieważ dane pomiarowe zostały udostępnione przez właściciela jako poufne i tylko na potrzeby tych badań, to w artykule zostały one unormowane.

Opis badanych obiektów

Badania prowadzono na podstawie ograniczonej liczby danych pomiarowych. Na rys. 1 przedstawiono topologię badanej FW zlokalizowanej w północnej części Polski. Farma składa się z 24 siłowni typu Vestas (do badań tej FW wykorzystano dane z losowo wybranych 5 siłowni). Dla FW pozyskano dane o prędkości i kierunku wiatru z anemometrów umieszczonych na każdej gondoli (na wysokości piasty: 100 m n.p.g.). Pomiary mocy wytwórczej oraz warunków wiatrowych dokonywano z krokiem 10-minutowym. Dane meteorologiczne oraz produkcyjne pozyskano za pomocą systemu SCADA z różnych okresów roku.



Rys. 1. Rozmieszczenie 5 z 24 siłowni wiatrowych rozległej FW

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

PL

Wszystkie siłownie FW są tego samego rodzaju. Prędkości wiatru na rozległej farmie wiatrowej mogą różnić się nawet o ponad 30%, czego doświadczył autor, analizując dane pomiarowe [29] nie tylko tej omawianej FW, ale również wielu innych funkcjonujących farm wiatrowych (22 sztuki) na terenie kraju w trakcie wieloletniej pracy zawodowej. Analiza danych pomiarowych FW umożliwiła zaobserwowanie zjawisk mających wpływ na ich wyjściową moc elektryczną. Podczas analizy czynników wpływających na produkcję energii elektrycznej FW zwrócono szczególną uwagę na dynamikę zmian kierunku wiatru. Przy zmianie kierunku wiatru dochodzi do zmiany wartości prędkości wiatru, która przekłada się na prędkość obrotową wirnika generatora. Prędkość wiatru ma największy wpływ na wolumen energii (odgrywa najistotniejszą rolę). Czy uwzględnienie w modelu dodatkowych czynników, np. kierunku wiatru, poprawia dokładność prognozy mocy wytwórczej FW?

Wpływ czynników na produkcję

W tab. 1 przedstawiono wartości współczynnika korelacji pomiędzy badanymi zmiennymi: prędkością wiatru pomierzoną na gondolach (oznaczoną jako VwG03÷VwG24), a także prędkością wiatru na maszcie meteorologicznym (oznaczoną jako VwM50) na wysokości 50 m n.p.g. oraz generacją mocy poszczególnych siłowni (oznaczoną jako Pc). W tabeli przedstawiono również korelację między średnią

prędkością wiatru (wyliczoną dla całej FW i oznaczoną jako VwFarma) a sumą generacji poszczególnych siłowni i sumą farmy (sumę energii FW oznaczono: PcFarma). Wyniki korelacji oznaczono kolorem żółtym (prędkość dla całej FW oznaczono: VwFarma oraz sumę energii FW oznaczono: PcFarma). Po usunięciu błędnych pomiarów ze zbiorów danych, jak widać w tab. 1, korelacja pomiędzy zmiennymi stała się silniejsza. Za błędne pomiary przyjęto m.in. wartości zerowe wynikające z wyłączenia siłowni. Silniejsza korelacja pomiędzy tymi wartościami występuje wtedy, gdy uśrednimy prędkość wiatru ze wszystkich turbin wiatrowych.

Uwzględnienie kierunku wiatru w modelach prognozy energii elektrycznej może poprawić jakość prognozy, lecz w mniejszym stopniu niż przy posiadaniu dokładniejszej prognozy pogody. Różnica w wolumenie generacji mocy (pomiędzy najbardziej skrajnymi okresami: letnim i zimowym) wynika m.in. przede wszystkim z gęstości powietrza (zimą jest większa niż latem) oraz mniejszej dynamiki i częstości zmiany kierunku wiatru. Na ogół jest tak, że w miesiącach letnich wiatry są słabsze, ale o większej zmienności niż w miesiącach zimowych. Z analizy wynika również, że należy posiadać informację o liczbie gotowych do pracy siłowni na farmie, a także ograniczenia regulacyjne w układach sterowania. Zwrócono również uwagę na to, że dynamiczne zmiany kierunku występują przy małych prędkościach wiatru (w okresie letnim),

co oznacza, że w modelach zimowych nie ma potrzeby uwzględniania dynamiki zmian kierunku wiatru. Więcej obserwacji autor przedstawił w swojej pracy doktorskiej [29].

Na potrzeby budowy i weryfikacji modelu prognostycznego potrzebne są dane pomiarowe o kierunku i prędkości wiatru oraz mocy (w niniejszym artykule chodzi o energię godzinową). Bezpośrednie pomiary na siłowniach dają możliwość poznania cech charakterystycznych całego obiektu, ale ze względu na lokalizację anemometru umieszczonego na gondoli za łopatami pomiary strumienia wiatru nie odzwierciedlają faktycznych warunków wiatrowych występujących na FW [29].

Punkty pracy turbiny i farmy leżą w innych punktach niż krzywej katalogowej. Ze względu na duże koszty zakupu systemu SCADA nie wszystkie farmy posiadają możliwość pomiaru Vw (prędkości wiatru) i Kw (kierunku wiatru) bezpośrednio na gondolach, a wartości generacji mocy FW rejestrowane są tylko przez układy pomiarowo-rozliczeniowe (liczniki) zamieszczone w punkcie przyłączenia farmy do sieci elektroenergetycznej (GPZ). Pomiary omawianej w niniejszym artykule FW pozyskano z zewnętrznego masztu meteorologicznego, zlokalizowanego w odległości nieprzekraczającej 10 km od FW. Należy wziąć pod uwagę, iż w zbiorach danych pomiarowych mogą występować dane obarczone błędem wynikającym np. z braku okresowej kalibracji anemometrów. Dane te mogą wpływać

	VwG03	VwG09	VwG10	VwG23	VwG24	VwM50	PcG03	PcG09	PcG10	PcG23	PcG24	VwFarma	PcFarma
VwG03	1,000												
VwG09	0,943	1,000											
VwG10	0,938	0,949	1,000										
VwG23	0,910	0,953	0,938	1,000									
VwG24	0,917	0,949	0,955	0,978	1,000								
VwM50	0,923	0,917	0,936	0,894	0,914	1,000							
PcG03	0,976	0,928	0,932	0,897	0,910	0,924	1,000						
PcG09	0,915	0,974	0,931	0,927	0,927	0,908	0,936	1,000					
PcG10	0,924	0,933	0,980	0,912	0,933	0,933	0,948	0,948	1,000				
PcG23	0,901	0,940	0,925	0,969	0,952	0,896	0,917	0,953	0,931	1,000			
PcG24	0,913	0,938	0,944	0,949	0,972	0,919	0,933	0,953	0,955	0,976	1,000		
VwFarma	0,962	0,982	0,978	0,979	0,983	0,938	0,949	0,957	0,958	0,960	0,966	1,000	
PcFarma	0,946	0,964	0,964	0,952	0,960	0,937	0,967	0,980	0,978	0,977	0,986	0,980	1,000

Tab. 1. Analiza korelacji pomiędzy prędkością wiatru na wysokości gondoli siłowni wiatrowych na wysokości masztu meteorologicznego po usunięciu błędnych pomiarów ze zbioru (marzec)

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

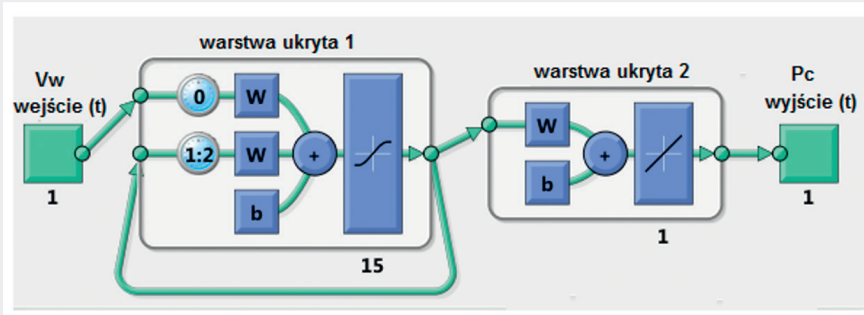
PL

na błędy prognoz generacji mocy. Stąd też poprawność danych do procesu uczenia należy wstępnie ocenić.


Struktura modelu prognozy energii elektrycznej

Prędkość wiatru (V_w) jest najważniejszym czynnikiem wpływającym na produkcję energii elektrycznej FW, co potwierdzają wartości w tab. 1. Inne czynniki wpływające na jej generację, tj. silne podmuchy wiatru, gęstość powietrza, stan gotowości siłowni czy szorstkość terenu, w badaniach pominięto ze względu na trudności w ich pozyskaniu. Pomiar kierunku wiatru (K_w) wykonano bezpośrednio na gondolach, a kalibracja punktu zerowego nie została przypisana dokładnie poszczególnym stronom świata, co uzasadniano w rozprawie doktorskiej [29]. Stąd też w badanych modelach prognozy energii elektrycznej nie uwzględniono również przesłonięcia.

Aby uzyskać odpowiedź na pytanie: czy uwzględnienie w modelu dodatkowych czynników, np. kierunku wiatru, poprawia dokładność prognozy mocy wytwórczej FW, zbudowano dwa modele prognostyczne, wykorzystujące strukturę sieci neuronowej Elmana. Częściowa rekurencja sieci Elmana różni się od pozostałych sieci rekurencyjnych (tj. Hopfielda, Hamminga, sieci BAM, sieci ART) tym, że pętla sprzężenia zwrotnego rozpoczyna się na wyjściu warstwy ukrytej, a nie na wejściu do modelu i kończy się na wejściu do modelu poprzez warstwę kontekstową, w której występują jednostkowe operatory opóźnienia sygnału propagowanego. Każdy neuron warstwy ukrytej ma swój odpowiednik w warstwie kontekstowej. Warstwa ta stanowi wspólnie z wejściami sieci wektor wejściowy. Przy zmianie stanu jednego neuronu wpływa się na całą sieć poprzez sprzężenie zwrotne. W efekcie uzyskuje się stan przejściowy, kończący się określonym stanem ustalonym (innym niż stan poprzedni). W celu uzyskania większej dokładności sieci neuronowej modyfikuje się jej wartości wag i progów (ang. *bias*) za pomocą algorytmów: zmiennej metryki Levenberga-Marquardta (oznaczonej dalej jako PcTrainlm) oraz Levenberga-Marquardta z wbudowaną regularyzacją bayesowską (sieć Bayesa, oznaczona dalej jako PcTrainbr). Metodą doświadczalną zbadano różne modele neuronowe z różną liczbą wejść i neuronów w warstwie ukrytej. Modele



Rys. 2. Model prognozy energii elektrycznej FW z jednym wejściem: prędkością wiatru



Rys. 3. Model prognozy energii elektrycznej FW z dwoma wejściami: prędkością i kierunkiem wiatru

zaimplementowano w programie Matlab. Do dalszych badań wybrano dwa modele: z jednym i dwoma wejściami. W pierwszym modelu na wejściu wprowadzono średnią prędkość wiatru (rys. 2), natomiast w drugim średnią prędkość (V_w) i kierunek (K_w) wiatru (rys. 3). Na wyjściu modeli otrzymuje się prognozowaną wartość generacji mocy (P_c) dla badanego obiektu.

Uczenie i testowanie modelu mocy (sieci Elmana)

W dalszej części opisano przebiegi uczenia i testowania modelu prognozy energii elektrycznej FW z jednym (rys. 2) i dwoma wejściami (rys. 3). Model FW to dwa różne modele, tj. zimowy i letni. Badania prowadzono, wykorzystując dostępne dane pomiarowe z farmy.

Model z jednym wejściem: średnia prędkość wiatru

Przedmiotem badań był model FW z jednym wejściem: prędkością wiatru. Liczbę neuronów dobrano metodą doświadczalną prób i błędów, kierując się błędem uczenia. Ustalono liczbę neuronów w warstwie ukrytej na 15. Celem badań było sprawdzenie, czy

na podstawie średniej prędkości wiatru dla FW o rozległej strukturze można uzyskać oczekiwaną ilość energii elektrycznej dla całego obiektu. Badanie wykonano dla średniej prędkości wiatru ze wszystkich 5 siłowni FW oraz prędkości wiatru pochodzącej z masztu meteorologicznego. Za wartość uczącą przyjęto sumę produkcji energii elektrycznej 5 siłowni w poszczególnych godzinach doby.

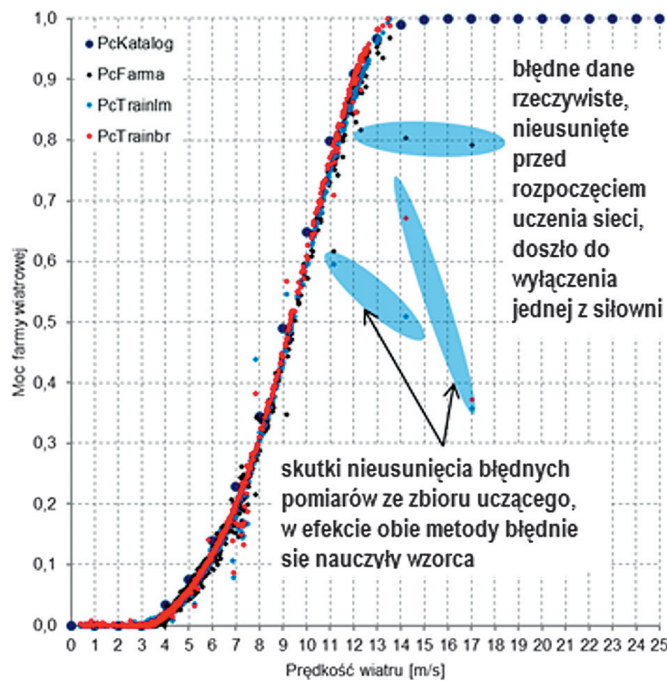
Na rys. 4 i 5 przedstawiono wyniki uczenia sieci metodą Levenberga-Marquardta (PcTrainlm) oraz metodą Levenberga-Marquardta z wbudowaną regularyzacją bayesowską (PcTrainbr). Na rys. 6a przedstawiono przebiegi uczenia z okresu letniego oraz efekty uczenia sieci metodami PcTrainlm i PcTrainbr. Znając tylko prędkość wiatru dla obiektu, należy uzgodnić, dla jakiej wysokości wartość ta została przygotowana, a w przypadku konieczności ekstrapolować prognozę na oczekiwaną wysokość turbin wiatrowych.

Model z dwoma wejściami: średnia prędkość i kierunek wiatru

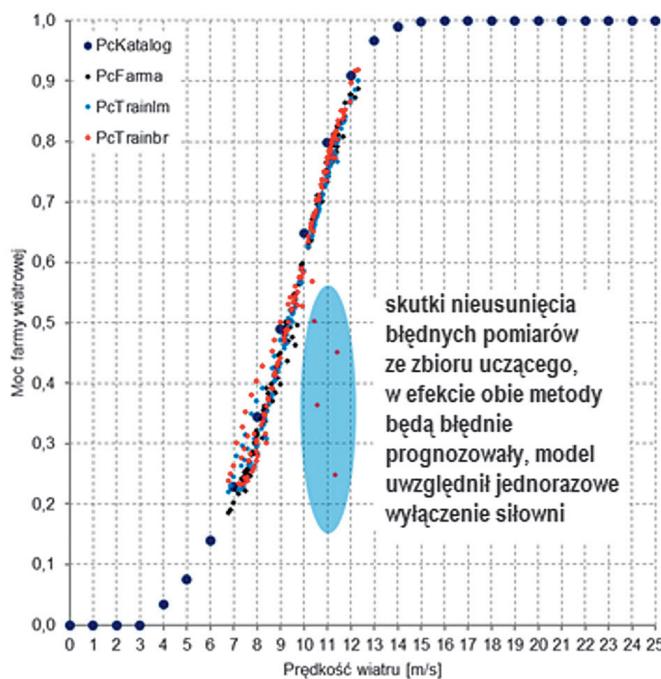
Przedmiotem badań jest model FW z dwoma wejściami: prędkością

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

PL



Rys. 4. Moc FW w funkcji prędkości wiatru – wynik uczenia sieci w okresie letnim



Rys. 5. Moc FW w funkcji prędkości wiatru – wynik testowania sieci w okresie letnim

i kierunkiem wiatru. Liczbę neuronów dobrano tą samą metodą, co w modelu z jednym wejściem. Ustalono liczbę neuronów w warstwie ukrytej na 15. Celem artykułu była ocena skuteczności modelu prognozy energii farmy,

po uwzględnieniu w modelu dodatkowych czynników, np. kierunku wiatru, czy poprawi się dokładność prognozy energii elektrycznej. Autor, analizując dane pomiarowe kierunku wiatru, zaobserwował, że kierunek również wpływa

na produkcję energii elektrycznej, lecz w mniejszym stopniu niż prędkość wiatru. Dostrzegł również to, iż pomiar kierunku wiatru na gondolach nie jest dokładnie zgodny ze stronami świata, co utrudnia wykorzystanie tej wartości w modelach prognostycznych [29]. W niniejszym artykule podjęto próbę budowy i zbadania modelu z uwzględnieniem kierunku wiatru.

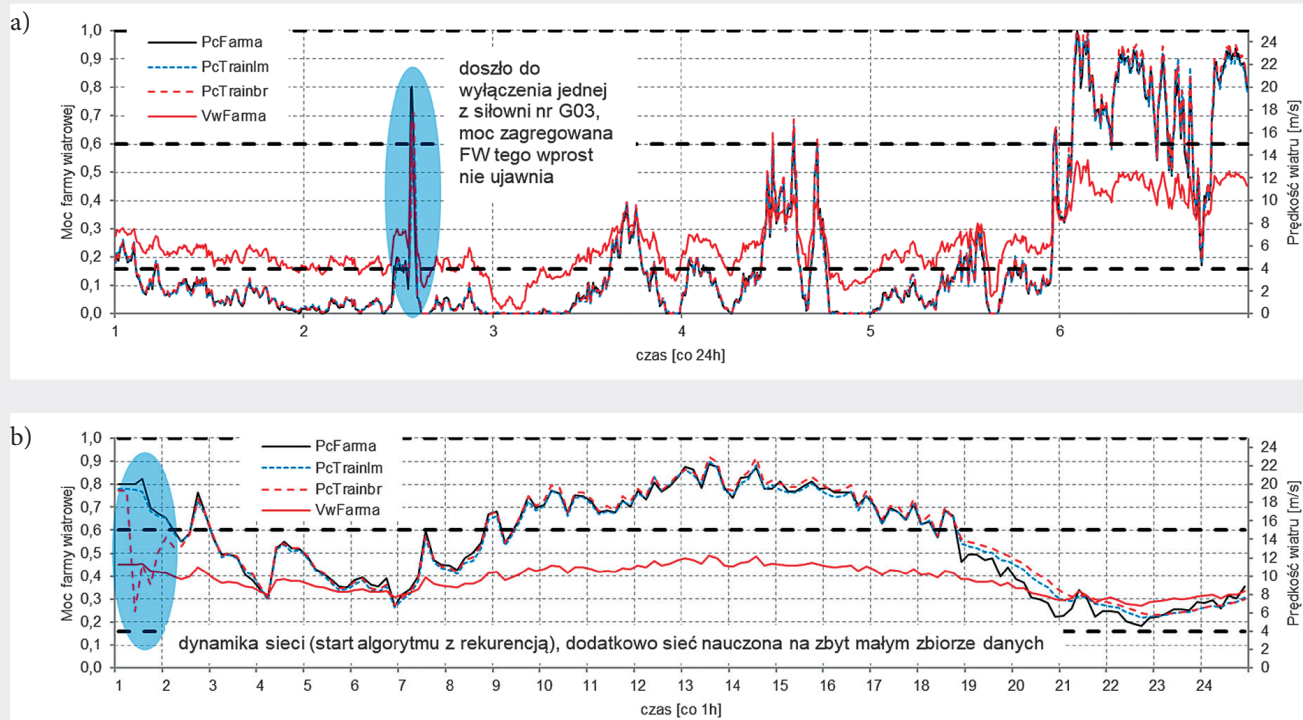
Z testów modelu FW wynika, że uwzględnienie kierunku wiatru, zwłaszcza o niepewnym sposobie pomiaru (braku właściwej kalibracji względem stron świata), może skutkować większymi błędami już na etapie uczenia sieci niż przy wykorzystaniu bardziej wiarygodnej i istotnej prędkości wiatru.

Badanie właściwości modelu mocy

Poniżej pokazano właściwości dynamiczne samego modelu neuronowego z jednym wejściem, aby określić odtwarzaną krzywą mocy dla określonych wymuszeń wiatrowych. Badania przeprowadzono, poddając model określonym wymuszeniom, czyli różnym ciągom danych wejściowych (prędkości wiatru). Na rys. 7–10 przedstawiono wyniki badań modelu uczonego dwoma metodami (PcTrainlm i PcTrainbr). W ramach badania sprawdzono odpowiedzi obu sieci na określone z góry wymuszenie (zmienną prędkość wiatru dla okresu letniego i zimowego). Rodzaj wymuszeń został przedstawiony na rys. 8. Natomiast na rys. 9 – odpowiedzi na wymuszenie. Analiza wykazała, że w zależności od charakteru wymuszenia odpowiedź modelu ulega zmianie. Dzieje się tak m.in. dlatego, że oba modele mocy są sieciami dynamicznymi (z częścią rekurencją). Zmiany na poniższych rysunkach oznaczono niebieskimi powierzchniami. Z wykresu wynika, że im większa dynamika zmian prędkości wiatru, tym większe są zmiany jakościowe w odpowiedzi (rys. 8), co przekłada się również na różne wolumeny produkcji energii elektrycznej. To, że sieć generuje wartości niższe, niżby wynikało z wartości katalogowych, jest oczywiste (bo występują straty przesyłowe, efekt przesłonięcia itp.), ale widać również inne przyczyny, jak na rys. 8, gdzie widoczna jest różnica między mocą dla modelu uczonego na danych zimowych i modelu uczonego na danych letnich. Różnica wynika z gęstości powietrza: mniejszej w okresie letnim niż zimowym, a także z większej dynamiki zmian kierunku wiatru.

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

PL




Rys. 6. Generacja mocy FW: (a) uczenie sieci (6 dni) i (b) testowanie modelu (1 doba) w okresie letnim

Zaobserwowano również to (rys. 10), że model uczony na danych letnich (PcTrainlmLato) jest bardziej odporny na gwałtowne zmiany prędkości wiatru niż model uczony na danych zimowych (PcTrainlmZima). Krótkotrwała gwałtowna zmiana prędkości wiatru (lub błędnie wprowadzone dane) może powodować długotrwałe zaburzenie w pracy sieci. Na szczęście model służy do predykcji, a prognozowany wiatr nie ulega tak gwałtownym zmianom. Prędkość wiatru w okresie letnim częściej ulega zmianie niż w okresie zimy, stąd model PcTrainlmLato ma dobrane optymalnie współczynniki wagowe sieci do zmiennych warunków wiatrowych. Oba modele neuronowe powinny być stosowane zamiennie w zależności od pory roku.

Wyniki badań – porównanie dwóch modeli mocy FW

Z własnych obserwacji autora wynika [29], że błąd prognozy mocy powstaje z błędów prognozy meteorologicznej, jak również samego modelu mocy FW. Aby wybrać właściwy model predykcji, należy przyjąć określoną miarę błędów. Zaproponowano cztery wskaźniki jakości, które umożliwiają wybór modelu. Na rys. 11–14 przedstawiono obliczone współczynniki jakości



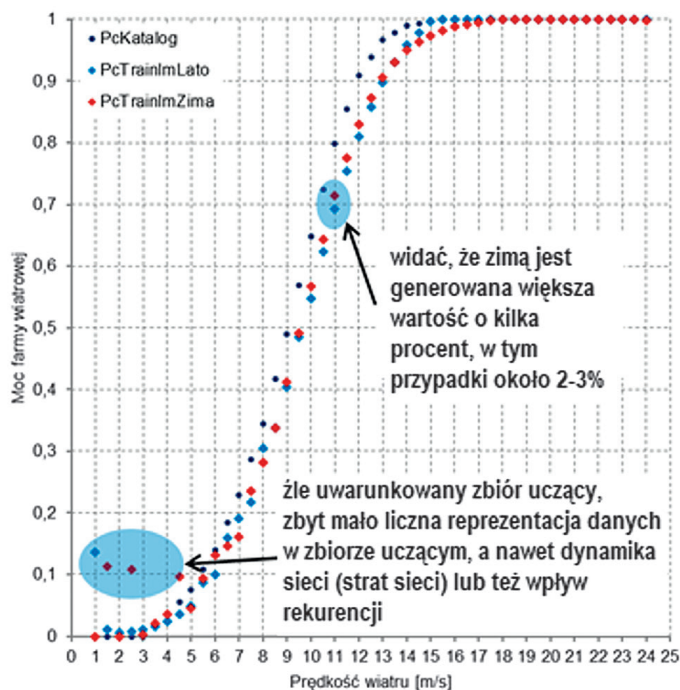
Rys. 7. Kontrolowane wymuszenie dla rosnącej liniowo prędkości wiatru

dla modelu z jednym (rys. 11–12) i dwoma (rys. 13–14) wejściami, które pozwalają na wybór modelu predykcji z grona różnych metod. Do oceny jakości modelu wykorzystano predykcję

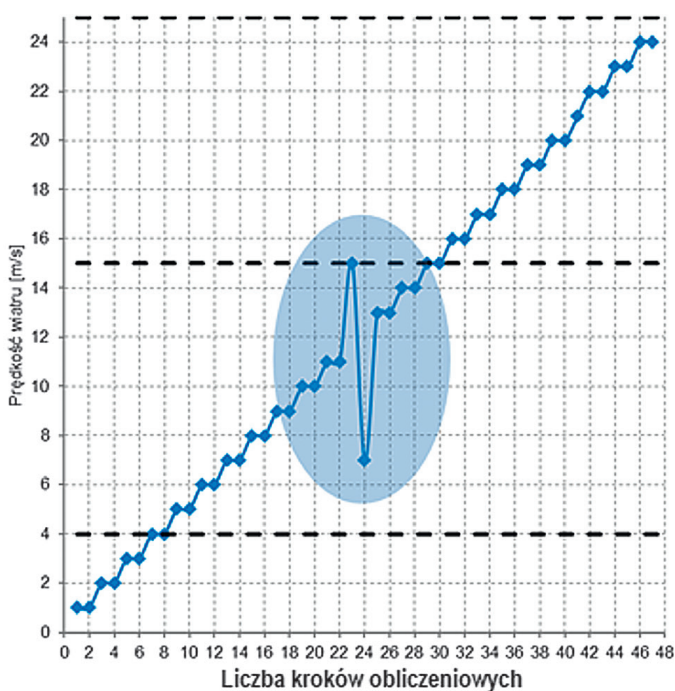
mocy FW uzyskaną na wyjściu modelu oraz rzeczywistą generację mocy. Do oceny jakości prognozy wybrano cztery kryteria, tj. sumę energii w danym okresie [MWh], błąd bezwzględny,

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

PL



Rys. 8. Odpowiedź modeli FW w funkcji prędkości wiatru



Rys. 9. Kontrolowane wymuszenie poprzez rosnącą prędkość wiatru

sumę odchyłek wartości prognozowanej od rzeczywistej oraz współczynnik zmienności (dynamika). Wyniki uczenia i testowania przedstawiono w tab. 2 i 3. Współczynnik zmienności przedstawia dynamikę zmienności mocy,

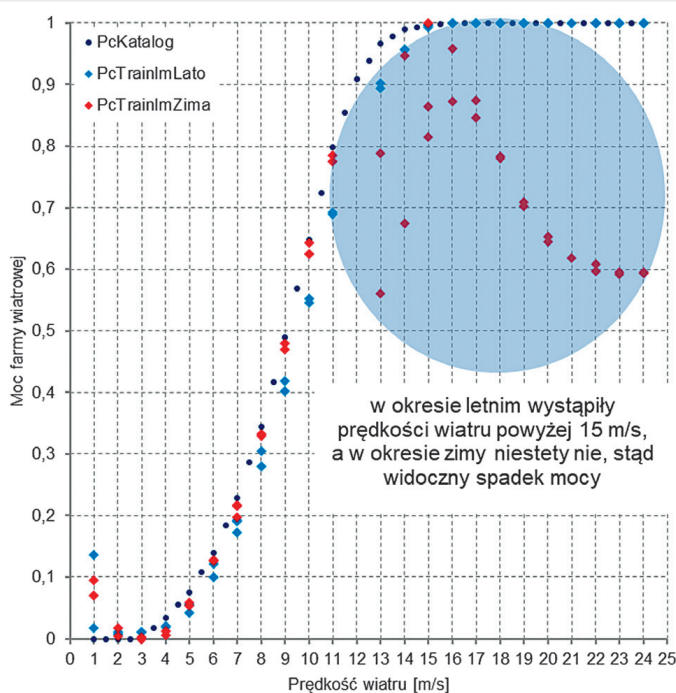
czyli skrajnych wartości oddalonych od średniej. Im wyższy współczynnik, tym większa dynamika mocy. Model prognozowania energii elektrycznej FW z niskim współczynnikiem zmienności zwiększa skuteczność prognozy.

Wybór skutecznego modelu mocy FW

W poniższych tabelach zestawiono wyliczone wskaźniki dla dwóch konfiguracji modelu mocy FW: modelu z jednym wejściem i modelu z dwoma wejściami. Wyniki pierwszego modelu oznaczono w tab. 2 i 3 jako VwFarma (model z prędkością wiatru), natomiast drugiego jako VwKwFarma (model z prędkością i kierunkiem wiatru). W tab. 2 przedstawiono wskaźniki jakości uczenia modelu na podstawie danych za okres 6 dni (próbka danych liczyła $N = 862$ pomiary), tj. sumę produkcji energii, z której można się dowiedzieć, czy dany model osiąga wolumeny energii elektrycznej zbliżone do rzeczywistej sumy za dowolny okres; błąd bezwzględny modelu całej generacji mocy; sumę odchyłek energii z modułu różnicy, aby się dowiedzieć, jak duży jest wolumen różnicy względem rzeczywistej mocy, oraz współczynnik zmienności produkcji energii modelu mówiący o dynamice zmienności produkowanej energii w badanym okresie. Model uczono na danych letnich i zimowych. Różnica w wolumenie energii (błąd bezwzględny) dla metody PcTrainlm modelu z jednym wejściem wynosi 0,5450, a dla metody PcTrainbr 0,0050. Mając te dwie wartości, nadal trudno podjąć decyzję, który model jest lepszy. Dlatego wylicza się sumę odchyłek energii (rys. 12), następnie współczynnik zmienności produkcji energii (rys. 14). Porównuje się metody uczenia i już wiadomo, który model jest lepszy. W tym badanym przypadku lepiej nauczył się model mocy za pomocą metody PcTrainbr. Analogicznie postępuje się z pozostałymi konfiguracjami modelu i badanymi okresami. Definiowanie innych parametrów, tj. średniej arytmetycznej, na tym etapie nie jest wskazane, bo ten parametr używany jest do wyliczenia odchylenia standardowego, więc został już uwzględniony. W tab. 3 przedstawiono wyniki jakości testowanego modelu dla okresu 1 doby (próbka danych liczyła $N = 144$ pomiary). Model testowano na danych letnich i zimowych. Na podstawie współczynnika zmienności można stwierdzić, że model uwzględniający tylko prędkość wiatru (VwFarma) jest skuteczniejszy niż model z kierunkiem wiatru. Co znajduje uzasadnienie w wynikach testowania modelu w tab. 3. Różnice predykcji mocy między modelami wynikają przede wszystkim z metody uczenia sieci.

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

PL



Rys. 10. Odpowiedź modeli FW w funkcji prędkości wiatru

Próbka	Pora roku i czynniki	VwFarma		VwKwFarma	
862	Metoda uczenia	lato	zima	lato	zima
Suma energii [MW]	PcFarma (Pc)	266,7010	799,2590	266,7010	799,2590
	PcTrainIm	266,1560	792,4970	266,9650	799,4900
	PcTrainbr	266,6960	799,2780	266,2420	803,3350
Błąd bezwzględny [MWh]	PcFarma (Pc)	0,00000	0,00000	0,00000	0,00000
	PcTrainIm	0,54482	6,76226	0,26389	0,23053
	PcTrainbr	0,00495	0,01867	0,45883	4,07575
Suma odchylenia energii [MW]	PcFarma (Pc)	0,0000	0,0000	0,0000	0,0000
	PcTrainIm	9,2750	18,6580	11,0340	17,6340
	PcTrainbr	8,2870	15,2990	62,0780	126,5920
Wsp. zmien. [%]	PcFarma (Pc)	1,34700	0,50500	1,34700	0,50500
	PcTrainIm	1,34800	0,51500	1,34700	0,50200
	PcTrainbr	1,34400	0,50400	1,30400	0,41600

Tab. 2. Jakość nauczonych modeli neuronowych przy średniej prędkości wiatru dla całej FW (próbka liczyła 862 pomiary – 6 dni)

Budowa jednego uniwersalnego modelu mocy FW, będącego dobrym estymatorem dla każdych warunków wietrznych, jest niemożliwa. Potwierdza to różnica błędów obu modeli względem rzeczywistej generacji mocy. Z badań wynika, że sieć potrafi nauczyć się rzeczywistych warunków FW dla wszystkich pór roku. Jak wynika z etapu testowania, metody, które sprawdzają się lepiej w okresie letnim, gorzej radzą

sobie w okresie zimowym i odwrotnie. Sieć neuronowa jest dobrym estymatorem krzywej mocy FW.

Podsumowanie

Celem artykułu była ocena skuteczności modelu prognozy energii elektrycznej farmy wiatrowej, czyli modelu odtwarzającego moc FW dla określonych warunków meteorologicznych. Model odtwarza charakterystyki konkretnej

FW. W ramach realizacji zadania poddano wnikliwej analizie dane pomiarowe pozyskane z rzeczywistych farm wiatrowych, ze szczególnym uwzględnieniem wpływu zmienności warunków meteorologicznych na wartość generowanej mocy oraz warunki wiatrowe występujące na tego typu obiektach.

W wyniku tej analizy ustalono, co ma wpływ na moc farmy i co ma wpływ na tyle istotny, że musi być uwzględnione w modelu. Wybrano dwie wielkości: prędkość wiatru jako wielkość podstawową i dodatkowo kierunek wiatru. Z analizy danych pomiarowych wynika, że każda FW ma różne warunki terenowe i model musi mieć konstrukcję, która te cechy odtworzy. Była to główna przyczyna wyboru modelu neuronowego. Do realizacji modelu wybrano sieć rekurencyjną Elmana uczoną metodą zmiennej metryki Levenberga-Marquardta oraz Levenberga-Marquardta z wbudowaną regularyzacją bayesowską. Wybór ten został poprzedzony szerokimi badaniami symulacyjnymi różnych struktur sieci uczonych różnymi metodami. Zaproponowano metodykę wyboru skutecznego modelu prognostycznego, wykorzystującego wybrane wskaźniki jakości, tj. sumę produkcji energii, błąd bezwzględny, sumę odchylenia energii oraz współczynnik zmienności mocy.

Opisane w artykule czynniki mające wpływ na moc farmy powinny być uwzględniane w modelach prognostycznych na różnych etapach procesu prognozowania. Wpływ na produkcję energii elektrycznej przez FW mają nie tylko warunki meteorologiczne, ale także sposób funkcjonowania, sterowania tego typu obiektem, jak i jej indywidualne warunki terenowe i rozlokowanie. Analizując dane pomiarowe, można znaleźć pewne zależności charakterystyczne. Analizy wykazały, iż mając do dyspozycji rzeczywiste dane meteorologiczne, tj. prędkość i kierunek wiatru, gęstość powietrza, opady dla lokalnych warunków oraz dane produkcyjne energii elektrycznej z poszczególnych siłowni i z licznika w Głównym Punkcie Zasilania, można zbudować sprawdzający się model prognostyczny. Otwartym zagadnieniem jest struktura modelu: deterministyczny – oparty na zjawiskach fizycznych i zależnościach analitycznych czy model behawioralny – zbudowany z wykorzystaniem sieci neuronowej.

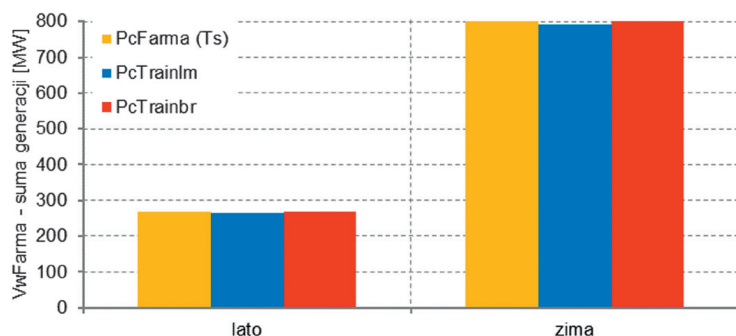
Wyniki symulacji na rys. 7–10 przeprowadzone na modelach prognozy energii elektrycznej FW (dla różnych pór roku:

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

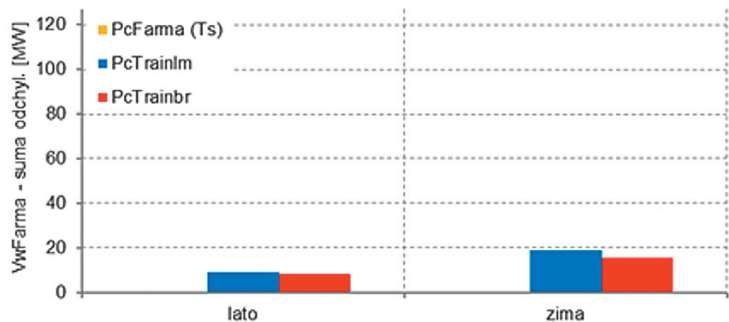
PL

Próbka	Pora roku i czynniki	VwFarma		VwKwFarma	
144	Metoda uczenia	lato	zima	lato	zima
Suma generacji energii [MW]	PcFarma (Pc)	104,3280	49,5640	104,3280	49,5640
	PcTrainlm	102,4930	49,9320	102,9300	49,7800
	PcTrainbr	100,1900	48,8130	89,1240	67,9830
Błąd bezwzględny [MWh]	PcFarma (Pc)	0,00000	0,00000	0,00000	0,00000
	PcTrainlm	1,83533	0,36820	1,39775	0,21629
	PcTrainbr	4,13847	0,75099	15,20446	18,41915
Suma odchyień energii [MW]	PcFarma (Pc)	0,0000	0,0000	0,0000	0,0000
	PcTrainlm	2,4330	7,7480	2,1500	4,2120
	PcTrainbr	4,8470	4,9920	16,5150	23,6310
Wsp. zmien. [%]	PcFarma (Pc)	0,25800	1,13800	0,25800	1,13800
	PcTrainlm	0,26500	1,09100	0,26400	1,10800
	PcTrainbr	0,28300	1,14500	0,22700	0,68300

Tab. 3. Jakość testowanych modeli neuronowych przy średniej prędkości wiatru dla całej FW (próbka liczyła 144 pomiary – 1 doba)



Rys. 11. Suma produkcji energii obu modeli neuronowych wraz z rzeczywistą generacją w różnych porach roku (dane z tab. 2, jedno wejście)



Rys. 12. Suma odchylenia od średniej produkcji energii w różnych porach roku (dane z tab. 2, jedno wejście)

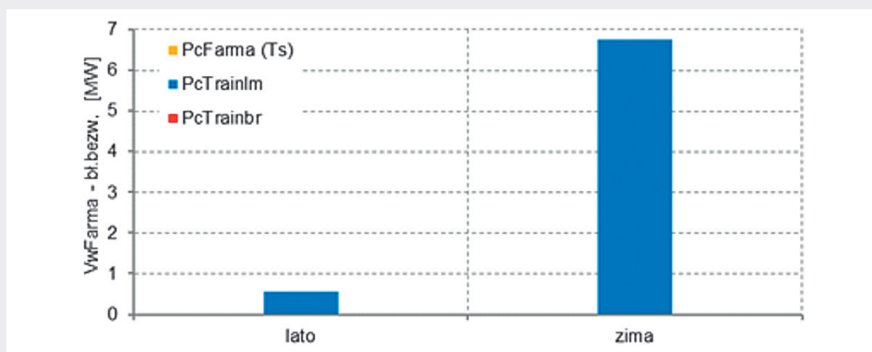
latem i zimą) wskazują, że sieci neuronowe potrafią wygenerować zbliżone prognozy do rzeczywistej generacji mocy i dzięki temu mogą stanowić

alternatywną metodę prognozy energii elektrycznej. Odchylenia prognozowanej energii od rzeczywistej mogą wynikać z właściwości modeli FW. Jak


zauważono, modele FW, które sprawdzają się lepiej w okresie letnim, gorzej radzą sobie w okresie zimowym i odwrotnie. Szczegółowe wyniki badań właściwości przedstawiono na rys. 8 i 10, które wykazały, że sieć neuronowa pomimo ograniczonego zbioru historycznych danych pomiarowych potrafi odtworzyć krzywe mocy zbliżone do krzywych katalogowych z uwzględnieniem cech charakterystycznych obiektu. Mając do wyboru model analityczny, statystyczny lub model neuronowy, zdecydowanie należy przeprowadzić analizę współczynników jakościowych, a następnie dokonać stosownego wyboru modelu. Przed ostatecznym wyborem modelu należy zawsze przeprowadzić fazę testów, aby uzyskać większe prawdopodobieństwo trafności prognoz. Warto również rozważyć model hybrydowy. Z badań wynika, że sieć o odpowiedniej strukturze jest dobrym estymatorem mocy wytwórczej farmy i może być stosowana alternatywnie przy tworzeniu modeli hybrydowych. Model mocy FW powinien być dopasowany do cech charakterystycznych farmy. Najlepszą prognozę energii elektrycznej FW uzyskuje się w horyzoncie krótkoterminowym, na podstawie danych z masztów meteorologicznych posadowionych w bliskiej odległości od obiektu. Odległość ta nie powinna przekraczać 10 km. Prognoza warunków pogodowych wykonana na podstawie danych pomiarowych z lokalnego masztu meteorologicznego umożliwia uzyskanie dokładniejszej prognozy energii elektrycznej, a tym samym uniknięcia znaczącego odchylenia na Rynku Bilansującym. Różnorodność struktur farm wiatrowych i liczba czynników wpływająca na produkcję energii elektrycznej sprawia, że trudno jest opracować jeden uniwersalny model prognostyczny. Stąd też najlepszymi modelami na rynku są modele hybrydowe (stworzone z kilku różnych modeli), które wykorzystują również modele behawioralne (m.in. sztuczne sieci neuronowe). Wybór właściwego modelu wymaga poświęcenia czasu oraz nakładu finansowego. Bez doświadczenia operatorskiego (człowieka wykonującego prognozę) wykonanie prognozy mocy może być obciążone dużym błędem i okazać się kosztownym uczestnictwem na Rynku Bilansującym, dlatego też w celu ograniczenia ryzyka warto poświęcić więcej czasu na etapie analizy danych pomiarowych.

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

PL



Rys. 13. Błąd bezwzględny dla różnych pór roku (dane z tab. 2, jedno wejście)



Rys. 14. Dynamika zmian produkcji energii dla różnych pór roku (dane z tab. 2, jedno wejście)

Autor przez 10 lat wyczerpał temat, dochodząc do głównego wniosku, że nie można stworzyć jednego uniwersalnego modelu prognozy energii elektrycznej, jednakowego dla każdej farmy wiatrowej. Potwierdziły to różne uzyskane wyniki prognoz dla wybranych farm wiatrowych za pomocą modeli neuronowych, wykonanych na potrzeby handlu hurtowego w jednej ze spółek obrotu. Oznacza to, że każdy tego typu obiekt wymaga indywidualnego doboru prognozy energii elektrycznej, aby skutecznie prognozować produkcję energii.

Powyższe wnioski nie pozwalają autorowi na prowadzenie dalszych badań w kierunku prognoz dobowo-godzinowych w ramach Rynku Dnia Następnego. Poza tym zmieniające się otoczenie rynkowe wymaga dalszych działań i opracowania nowych modeli prognostycznych sprawdzających się w krótszym horyzoncie czasowym (godzinowym, minutowym) na potrzeby obu rynków, tj. Rynku Dnia Bieżącego i Rynku Bilansującego. Jak wynika z opublikowanego komunikatu na stronie OSP [30], już od 2021 roku Rynek Bilansujący przejdzie gruntowne

zmiany w zakresie zasad jego funkcjonowania, co znacząco wpłynie na koszty uczestnictwa.

Bibliografia

1. Dyrektywa Parlamentu Europejskiego i Rady 2009/28/WE z dnia 23 kwietnia 2009 r. w sprawie promowania stosowania energii ze źródeł odnawialnych zmieniająca i w następstwie uchylająca Dyrektywę 2001/77/WE oraz 2003/30/WE, Dz. Urz. UE L 140 z 5.06.2009.
2. Rząd pracuje nad zmianą zasady 10H. Co zaproponuje? [online], <https://www.gramwzielone.pl/energia-wiatrowa/103511/rzad-pracuje-nad-zmiana-zasady-10h-co-zaproponuje> [dostęp: 30.07.2020].
3. Flores J.J., Graff M., Rodriguez H., Evolutive design of ARMA and ANN models for time series forecasting, *Renewable Energy* 2012, Vol. 44, s. 225–230.
4. Soman S.S. i in., A review of wind power and wind speed forecasting methods with different time horizons,

North American Power Symposium (NAPS), 2010, IEEE Xplore [online], https://www.researchgate.net/publication/224188805_A_review_of_wind_power_and_wind_speed_forecasting_methods_with_different_time_horizons [dostęp: 28.10.2020].

5. Jursa R., Wind power prediction with different artificial intelligence models [online], https://www.researchgate.net/publication/228964192_Wind_power_prediction_with_different_artificial_intelligence_models [dostęp: 28.10.2020].
6. Sveinbjornsson S., Analysis of WasP (Wind Atlas Analysis and Application Program) in complex topographical conditions using measured production from a large scale wind farm, A thesis submitted in partial fulfillment of the requirements for the degree, Department of Civil and Environmental Engineering, University of Washington 2013.
7. Zeng J., Qiao W., Support Vector Machine-Based Short-Term Wind Power Forecasting [online], <https://core.ac.uk/download/pdf/189669024.pdf> [dostęp: 28.10.2020].
8. Wind Energy Division, Risø DTU, [www.wasp.dk](http://www.risoe.dtu.dk), <http://www.risoe.dtu.dk>.
9. EMD International A/S [online], www.emd.dk/WindPRO [dostęp: 28.10.2020].
10. RETScreen International [online], www.retscreen.net [dostęp: 28.10.2020].
11. Rubanowicz T., Metody predykcji produkcji mocy parku wiatrowego, *Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej* 2008, nr 25, s. 145–149.
12. Rubanowicz T., Bogalecka E., Ocena charakterystyki mocy parku wiatrowego, PES-7, VII Ogólnopolska Konferencja Naukowo-Techniczna PTETiS, Kościelisko 22–26.06.2009.
13. Rubanowicz T., Bogalecka E., Analiza charakterystyk parku wiatrowego, *Wiadomości Elektrotechniczne* 2010, nr 2, s. 15–20.
14. Rubanowicz T., Bogalecka E., Neuronowy model mocy farmy wiatrowej, *Mechanik* 2010, nr 7, s. 579–586.
15. Rubanowicz T., Bogalecka E., Modele farmy wiatrowej na potrzeby prognozowania mocy, X Krajowa Konferencja Naukowa SENE, Łódź 2011.

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 36–45. When referring to the article please refer to the original text.

PL

16. Rubanowicz T., Bogalecka E., Model fizyczny – czy neuronowy? – narzędzia do predykcji mocy wytwarzanej przez elektrownie wiatrowe, XVI Międzynarodowa Szkoła Komputerowego Wspomagania Projektowania, Wytwarzania i Eksploatacji, Jurata 2012.
17. Rubanowicz T., Budowa modelu prognostycznego farmy wiatrowej w środowisku MATLAB, XXII Seminarium Zastosowanie Komputerów w Nauce i Technice, Oddział Gdański PTETiS, Gdańsk 2012.
18. Landberg L., Short-term prediction of the power production from wind farms, *Journal of Wind Engineering and Industrial Aerodynamics* 1999, Vol. 80, No. 1–2, s. 207–220.
19. Barbero A., Lopez J., Dorronsoro J.R., Kernel methods for Wide area wind power forecasting [online], <https://repositorio.uam.es/handle/10486/665710> [dostęp: 28.10.2020].
20. Nielsen T.S., Online prediction and control in nonlinear stochastic systems, Technical University of Denmark, Ph.D. Thesis No. 84, 2002 [online], <http://www2.imm.dtu.dk/pubdb/edoc/imm792.pdf> [dostęp: 30.10.2020].
21. Saint-Drenan Y-M., Wind power predictions analysis, cz. 2, Economical analysis, ECN-I-02-011 (2002).
22. Rubanowicz T., Bogalecka E., Warunki wiatrowe na rozległej farmie wiatrowej, *Mechanik* 2011, nr 7, s. 29–36.
23. Monteiro C. i in., Wind power forecasting: State-of-the-Art 2009, Decision and Information Sciences Division, ANL/DIS-10-1, Argonne National Laboratory 2009.
24. Holttinen H., Optimal electricity market for wind power, *Energy Policy* 2005, Vol. 33, s. 2052–2063.
25. Waldl I., Kariniotakis G.N., The Anemos wind power forecasting platform technology – techniques and experiences, EWEC 2006.
26. Parkers J., Tindal A., Forecasting Short Term Wind Farm Production in Complex Terrain, Garrard Hassan and Partners Ltd [online], www.gl-garrardhassan.com [dostęp: 30.07.2020].
27. Lichota A., Prognozowanie krótkoterminowe na lokalnym rynku energii elektrycznej, rozprawa doktorska, Akademia Górniczo-Hutnicza, Kraków 2006.
28. Centrum Informacji o Rynku Energii [online], www.cire.pl [dostęp: 30.07.2020].
29. Rubanowicz T., Prognozowanie mocy wytwórczej farmy wiatrowej, rozprawa doktorska, Politechnika Gdańska, Gdańsk 2019.
30. Komunikat OSP z dnia 21 maja 2020 [online], <https://www.pse.pl/-/spotkanie-informacyjne-dotyczace-zmian-zasad-funkcjonowania-ryнку-bilansujacego> [dostęp: 30.07.2020]

Tomasz Rubanowicz

dr inż.

Energa Obrót SA z Grupy ORLEN

e-mail: tomruban@gmail.com

Absolwent Wojskowej Akademii Technicznej na kierunku mechatroniki i studiów doktoranckich Politechniki Gdańskiej w zakresie: automatyka, elektronika i elektrotechnika. Autor i współautor wielu publikacji, uczestnik konferencji branżowych. Do jego zainteresowań należy m.in.: zastosowanie metod sztucznej inteligencji, odnawialne źródła energii, efektywność energetyczna.