

# Options to Improve the Quality of Wind Generation Output Forecasting with the Use of Available Information as Explanatory Variables

## Authors

Rafał Magulski  
Tomasz Pakulski

## Keywords

forecasting, statistical methods, neural networks

## Abstract

Development of wind generation, besides its positive aspects related to the use of renewable energy, is a challenge from the point of view of power systems' operational security and economy. The uncertain and variable nature of wind generation sources entails the need for the TSO to provide adequate reserves of power, necessary to maintain the grid's stable operation, and the actors involved in the trading of energy from these sources incur additional of balancing unplanned output deviations.

The paper presents the results of analyses concerning the options to forecast a selected wind farm's output exercised by means of different methods of prediction, using a different range of measurement and forecasting data available on the farm and its surroundings. The analyses focused on the evaluation of forecast errors, and selection of input data for forecasting models and assessment of their impact on prediction quality improvement.

**DOI: 10.12736/issn.2300-3022.2015203**

## 1. Introduction

There are many ways currently used in the world to correct numerical weather forecasts. The most commonly used is a group of statistical *ex post* methods, using historical data. In the literature, the most common methods of correcting numerical weather forecasts are [1, 2, 7]:

- statistical methods, which seek formulas for the relationship between forecast variables with actual variables, e.g. regression methods,
- artificial intelligence methods, whereby correlations between input variables and the output (anticipated) variable, are used in the learning process, e.g. artificial neural networks (ANN).

The main objective of this study was to investigate the possibility of correcting numerical weather forecasts in order to improve the quality of wind generation output in a 24 hours perspective, using statistical methods and artificial neural networks [8].

For the simulation historical data from a selected wind farm was used. The input data sample, covering approx. 300 days, included numerical weather forecasts, measurement of actual weather conditions, and the farm's actual output.

A solution was sought for that would result in the smallest mean absolute error of wind farm output forecast NMAE<sup>1</sup>, defined as:

$$NMAE = \frac{MAE}{P_{FW}}$$

where:

$$MAE = \frac{1}{N} \sum_{I=1}^N |PROG_I - POM_I|$$

where:

$P_{FW}$  – wind farm rated power,  $PROG_I$  – forecast value,  $POM_I$  – measured (actual) value,  $N$  – number of samples.

Based on numerical weather forecasts and theoretical power curves of individual turbines, a reference forecast of the wind farm output was determined, and then prediction errors in each hours of the day (reference forecast).

A set of test data used for the ANN – based simulation was separated from the main set at random. For testing the trained

<sup>1</sup> NMAE – Normalized mean absolute error.

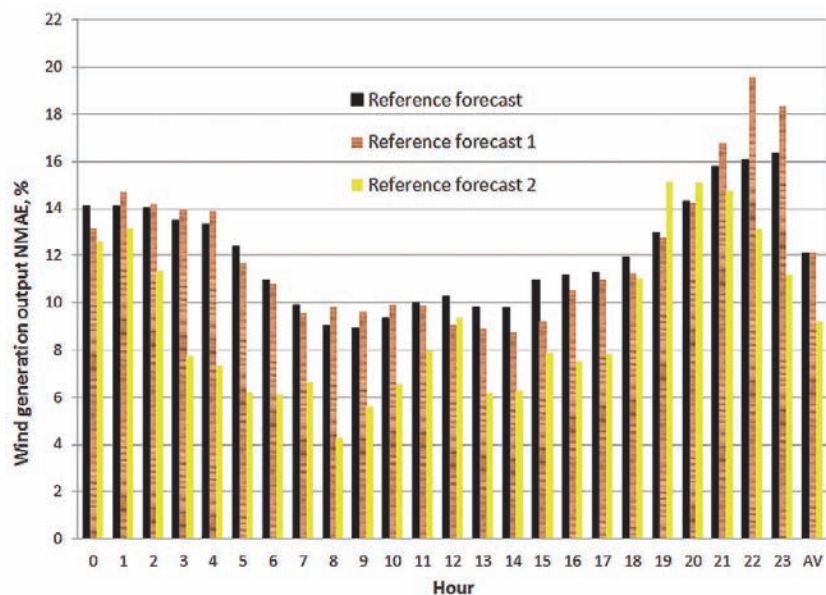


Fig. 1. Reference forecast errors throughout the day

network a few days were selected from each month of the year (reference forecast 1)<sup>2</sup>. Given the random nature of wind, in terms of output errors the presented selection was representative of the whole period under consideration (Fig. 1). In order to verify the usefulness of the structures, for which the smallest errors of reference forecast 1 were achieved, alternative simulations were performed for reference forecast 2, where the test set consisted of a selected continuous 14-day period of the year<sup>3</sup>. The remaining samples were used in the learning process.

## 2. Improving the generation output forecast quality by adjusting numerical weather forecast

### 2.1. Statistical methods

Actual wind speed deviations from the forecast were analysed, in particular by examining the value and stationarity of average deviations. It was found that projected values' average deviations from the actual values are non-zero and variable in their nature, depending on the forecast wind speed. It can be therefore concluded that these deviations feature a statistical tendency, the removal of which should increase the wind forecast accuracy, and consequently improve the wind farm generation output forecast quality. On this basis many models of the wind forecast adjustment were built, based on the linear regression method. These models determine the change in *ex post* forecasts in such a manner that the average deviation from the measured values was close to zero. The modelling has taken into account different periods of data sampling for the adjustments' determination, and the data's division into classes due to time of day and wind direction. Selected for further analysis

was the model which in a 14-day test period had reached the smallest wind speed forecast errors.

### 2.2. Artificial intelligence methods

For the simulations artificial neural networks (ANN) were used, included in the Neural Network package in the Matlab environment.

One-directional neural networks built on a multilayer perceptron (MLP) were tested in the study, according to an adapted algorithm presented in [6]. Several hundred structures of two- and three-layer networks were tested with variable [3, 4]:

- number of neurons in hidden layer/layers
- activation function of neurons in each layer
- network learning algorithm
- number of network learning iterative cycles.

In the analysed variant the output forecasts were adjusted in two stages (cascade model) [5]. In the first stage the numerical weather forecasts were adjusted, which in turn were used to determine the adjusted farm output forecasts. The following options were considered:

- Option A – adjustment of individual variables making up a numerical forecast (single-output network)
- Option B – joint adjustment of numerical weather forecast (multi-output network)<sup>4</sup>.

The simulations for each hour of the day were performed separately. For each hour of the day the structure was chosen for which the mapping errors were the smallest.

<sup>2</sup> For trained network quality testing 20% of all samples in the set were selected, i.e. every fifth day.

<sup>3</sup> Another purpose of the presented division was also an opportunity to compare the results obtained using artificial neural networks and statistical methods.

<sup>4</sup> The forecast errors throughout the day, as illustrated in Fig. 2 and 3, refer to the structures for which the smallest mapping error was achieved. AV – daily average.

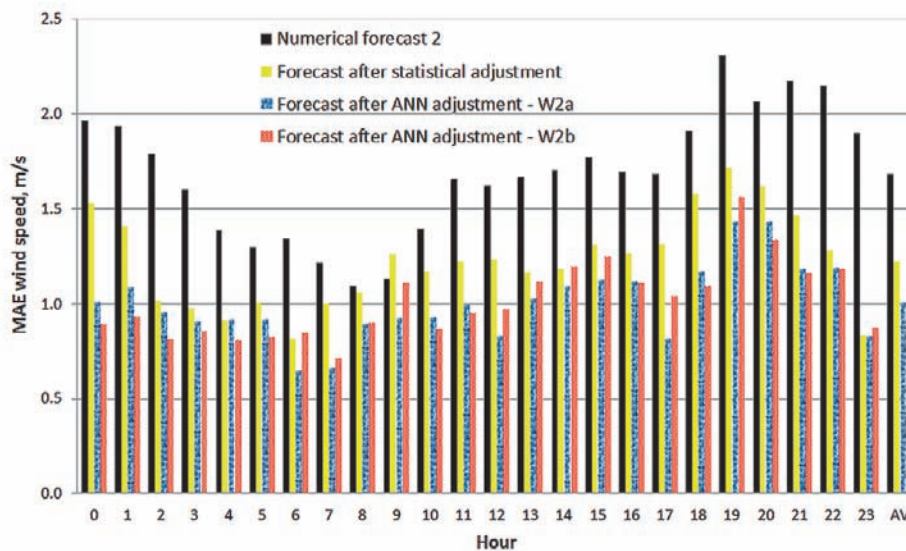


Fig. 2. Adjustment of numerical weather forecasts

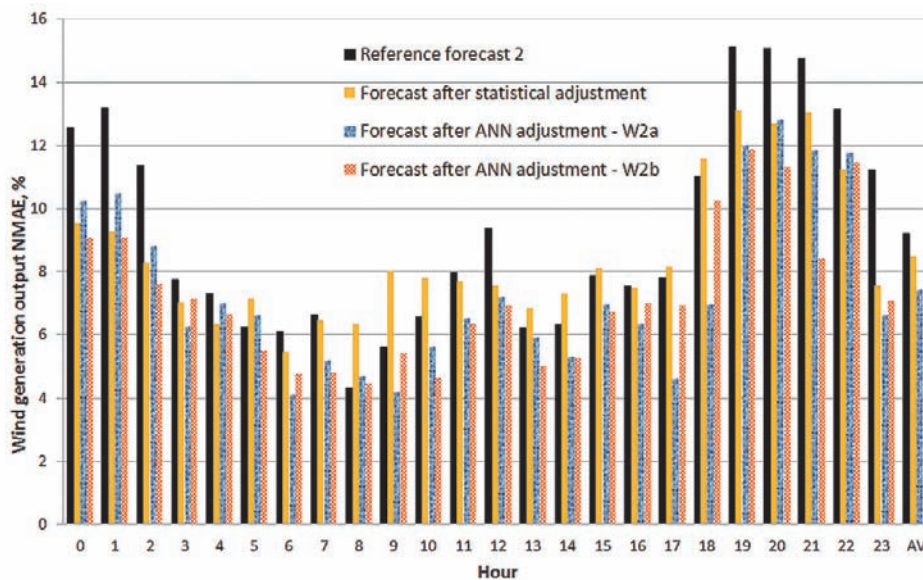


Fig. 3. Wind generation output adjustment using adjusted numerical forecasts

### 2.3. Comparison of the results

The results (Fig. 2) indicate daily volatility of the forecasting errors. The research has shown that it is possible to reduce the MAE error of numerical weather forecasts:

- in the case of statistical methods by 0.1–1.1 m/s – on average by approx. 0.5 m/s
- in the case of AAN by 0.2–1.1 m/s – daily average by approx. 0.7 m/s<sup>5</sup>.

The NMAE error of the adjusted farm output forecast determined based on the adjusted numerical forecasts (Fig. 3) decreased compared to the reference forecast, depending on the hour of the day:

- statistical methods: by –2.4% to 3.9% – daily average by approx. 0.7%
- artificial neural networks: by –0.1% to 6.3% – daily average by approx. 2.0%.<sup>6</sup>

The daily-average wind speed forecast error in the regression model selected for the weather forecast adjustment was 1.2 m/sec, an improvement of approx. 0.5 m/s compared to the reference forecast, and the NMAE error of the generation output forecast after the other statistical adjustments amounted to 8.5%, i.e. approx. 0.7% less compared to the reference forecast. The results obtained with the use of artificial neural networks are listed in Tab. 1.

<sup>5</sup> In the both AAN options considered, i.e. W2a and W2b, similar results were obtained.

<sup>6</sup> In the case of the simulation for reference forecast 2.

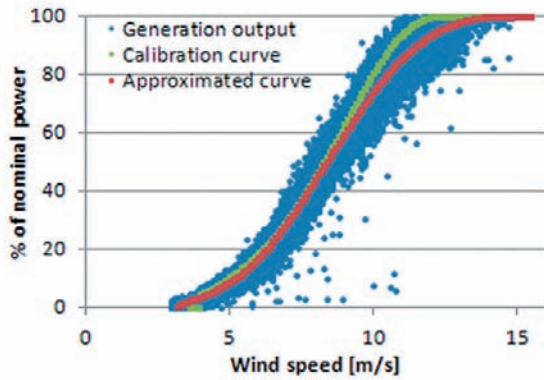


Fig. 4. Approximation of actual wind farm power curve




Fig. 5. Approximation of adjustment curve with power losses within wind farm

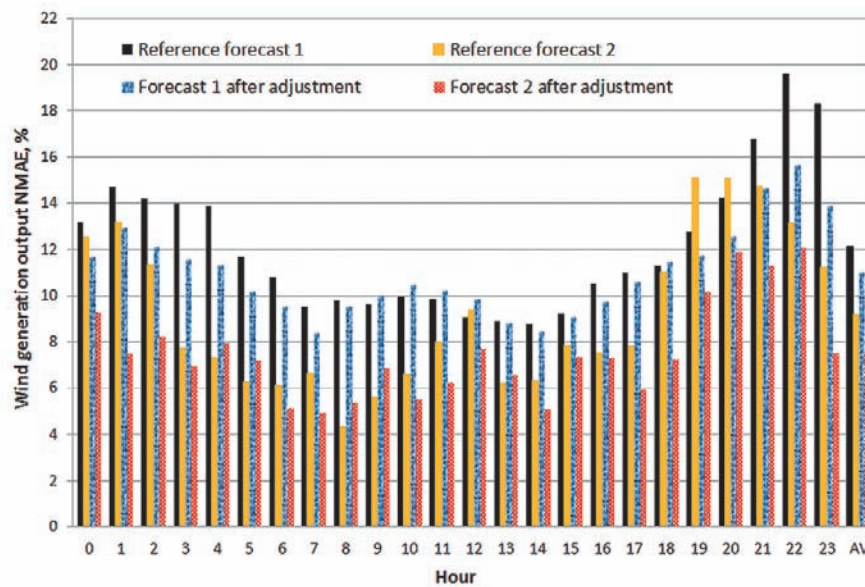


Fig. 6. Adjustment of wind generation output using actual output details

Feature	Daily average MAE error of numerical forecast, m/s		Daily average error of wind generation output, NMAE, %	
	Numerical forecast 1	Numerical forecast 2	Reference forecast 1	Reference forecast 2
<b>Selection of the structures with the smallest errors in each hour of the day</b>				
Before adjustment	1.71	1.69	12.2	9.2
After adjustment	1.33	1.02	10.7	7.2
<b>Forecast error reduction</b>	<b>0.38</b>	<b>0.67</b>	<b>1.5</b>	<b>2.0</b>
<b>Selection of the structures with the smallest errors in the whole day</b>				
Before adjustment	1.71	1.69	12.2	9.2
After adjustment	1.38	1.21	11.3	8.9
<b>Forecast error reduction</b>	<b>0.33</b>	<b>0.48</b>	<b>0.9</b>	<b>0.3</b>

Tab. 1. Adjustment of numerical weather and wind generation output forecasts

### 3. Adjustment of wind generation output forecasts using the actual output details

#### 3.1. Statistical methods

On the basis of historical wind measurements and the power outputs of each turbine the actual wind farm output curve was approximated depending on wind speeds. As seen in Fig. 4, the resulting curve is quite different from the calibration curve, which was adopted as the basis for reference forecasting.

To take into account in the generation output forecast the energy losses resulting from the electricity transfer and transformation within the wind farm, combined data of each wind turbine's output was used, as well as details of the electricity input to the power system as measured at the farm's interconnection point. The difference between these values results from the farm's internal electricity losses. By way of the curve's approximation on the basis of measurement data (Fig. 5), the dependence of the

<sup>7</sup> Ignored were details of any unexpected interruption in the turbines' operation, taking into account only planned outages related to ongoing inspections, maintenance and/or repairs. Planned deficits in the wind farm's output can be used to adjust the output forecast.

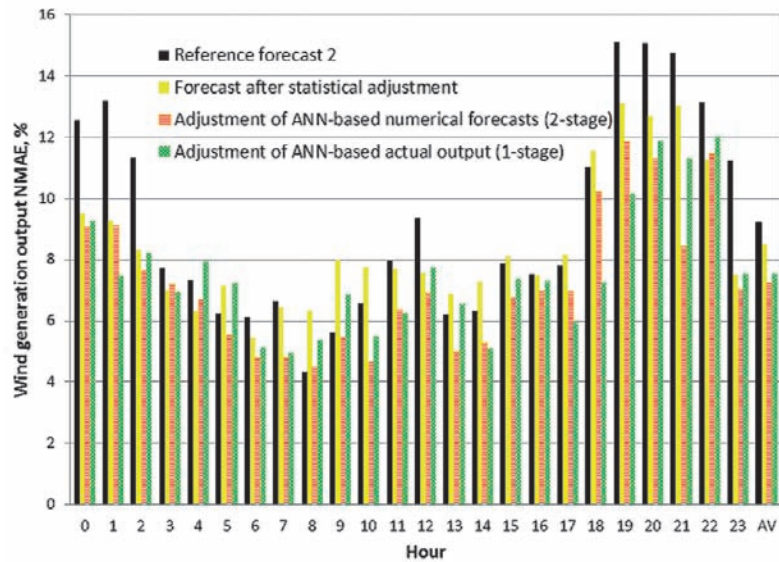


Fig. 7. NMAE errors of wind generation output before and after adjustment

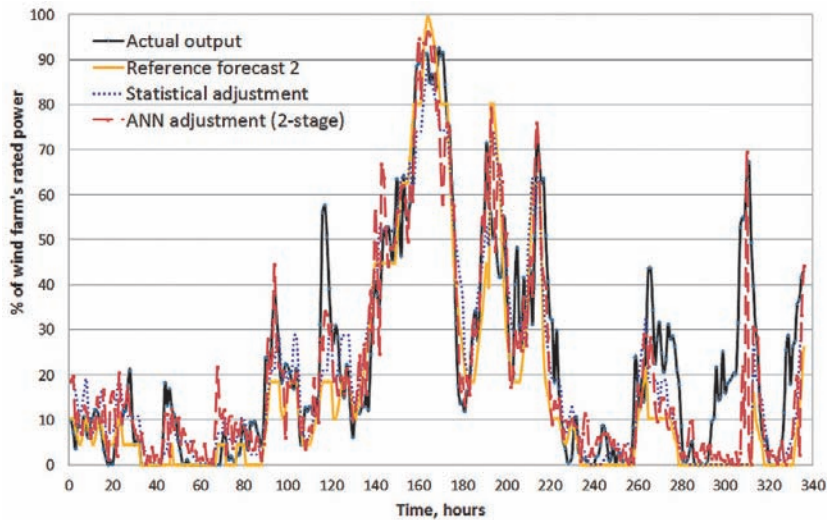


Fig. 8. Wind generation output in the simulated 14-day period

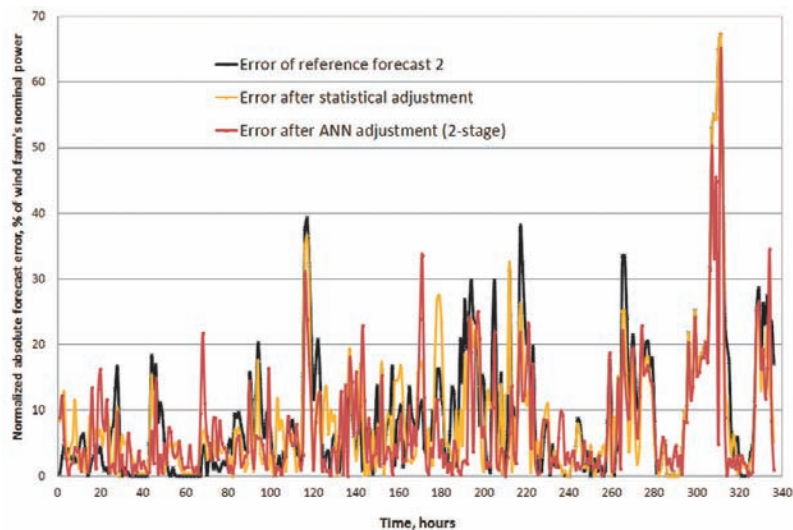


Fig. 9. Wind generation output forecast errors before and after adjustment in the simulated 14-day period

farms' electrical losses on the wind speed was identified, and on this basis a factor of the adjustment of the gross output generated on each mast into the net input to the grid was determined. Details of each wind turbine's status were used. The turbine's status determines its operating state and indicates the reason for its unavailability. Historical data about the turbine statuses were converted so that they could be treated as the previously made forecast of the wind farm's availability<sup>7</sup>.

The starting points for wind farm generation output forecasting were the wind forecasts adjusted in accordance with the adopted linear regression model. The generation output was calculated based on the acquired approximation of the wind farm's actual power curve, and then adjusted by a planned wind farm availability rate and the rate of electrical losses in the farm.

### 3.2. Artificial intelligence methods

In the considered option (Fig. 6) the output forecasts were adjusted directly on the basis of numerical weather forecasts, using historical data of the farm's actual output, and the operating statuses of individual turbines.

The simulation results shown in Fig. 6 indicate that it is possible to reduce the MAE error of wind generation output depending on the hour of the day within<sup>8</sup>:

- Reference forecast 1: –0.8% to 4.5% – daily average by approx. 1.2% from 12.2% to 11.0%
- Reference forecast 2: –1.2% to 5.7% – daily average by approx. 1.7% from 9.2% to 7.5%<sup>9</sup>.

### 4. Comparison of the quality of adjusted generation output forecasts

Fig. 7 shows a comparison of the NMAE errors of wind generation output forecast in each hour of the day before and after the adjustment, and Fig. 8 shows the wind generation outputs in the simulated 14-day period.

Fig. 9 shows a comparison of wind generation output forecast errors before and after adjustment in the simulated 14-day period.

### 5. Summary and conclusions

This paper reports an attempt to improve wind generation output forecast quality by adjusting numerical weather forecasts using statistical methods and artificial neural networks. The study has shown:

- possibility of increasing the forecasting quality by using artificial intelligence methods to a greater extent than statistical methods
- possibility of reducing the MAE error of daily average numerical weather forecasting by approx. 0.5 m/s (statistical methods) –0.7 m/s (ANN)
- reduction of the average daily NMAE error of the wind farm output forecast based on the adjusted numerical forecasts (2-stage adjustment) by approx. 1.5–2.0%<sup>10</sup>

- reduction of the average daily NMAE error of the wind farm output forecast based on the adjusted numerical forecasts (1-stage adjustment) by approx. 1.2–1.7%
- reduction of the average daily NMAE error of the wind farm output forecast based on the numerical forecasts adjusted using regression methods by approx. 0.4–0.7%
- preference for the choice of different neural structures to adjust forecasts in each hour of the day
- the components used to determine the reference forecast featured a tendency for mutual netting of the errors generated by it (wind speed forecasts generally led to underestimation of the wind farm output forecast, and the adoption of the theoretical power curve resulted in the output's overestimation), from which the forecast benefited and which could contribute to reducing the effects of using tools for forecast quality improvement
- the forecasting quality improvement by using neural networks requires continuous updating of input data used in the learning process. Extending the wind sources' performance observation period up to several years will allow achieving a better quality of forecast.

### REFERENCES

1. Sweeney C., Lynch P., Nolan P., Reducing errors of wind speed forecasts by an optimal combination of post-processing methods, Department of Meteorology and Climate Centre, Dublin, 2011.
2. Prondziński Z., Rubanowicz T., Zryczłowana usługa operatora handlowo-technicznego na potrzeby rozwoju energetyki wiatrowej w Polsce [The flat-rate service of commercial and technical operator for the development of wind power generation in Poland], *Acta Energetica* 2004, No. 19.
3. Hernandez L., Artificial Neural Network for Short-Term Load Forecasting in Distribution Systems, *Energies* 2014, 7 1576-1598, ISSN1996-1073, March 2014, collective study.
4. Perez-Llera C., Fernandez-Baizan M.C., Gonzalez del Valle V., Local Short-Term Prediction of Wind Speed: A Neural Network Analysis, Universidad Politecnica de Madrid, Spain.
5. Moghaddas-Tafreshi, S.M., Panahi D., One-hour-ahead forecasting of wind turbine power generation using artificial neural networks, K.N. Toosi University of Technology, Teheran, Iran.
6. Mao J., Zhang X., Li J., Wind power forecasting based on the BP neural network, Beifang University of Nationalities, Yinchuan, China.
7. Sweeney C. et al., Post-processing COSMO output for improved wind forecast, Meteorology and Climate Centre, University College Dublin, Ireland, April 2012.
8. Selcuk Nogay H., Akinci T.C., Eidukeviciute M., Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey, *Journal of Energy in Southern Africa*, November 2012, Vol. 23, No. 4.

<sup>8</sup> In the case of selection of the structures with the smallest errors in each hour of the day.

<sup>9</sup> In the case of adoption of the structure with the smallest NMAE in the whole day, the forecast error was, respectively: 11.3% (for reference forecasts 1) and 9.1% (for reference forecast 2).

<sup>10</sup> Depending on the reference forecast.

---

### **Rafał Magulski**

Gdańsk Branch of the Institute of Power Engineering

e-mail: r.magulski@ien.gda.pl

Graduated in management and marketing from Gdańsk University of Technology, Faculty of Management and Economics (1998). A senior technical and engineering specialist in the Department of System Strategy and Development, Institute of Power Engineering, Gdańsk branch.

His professional interests include problems of market functioning in the power sector, and power system pre-development studies.

### **Tomasz Pakulski**

Gdańsk Branch of the Institute of Power Engineering

e-mail: t.pakulski@ien.gda.pl

Graduated in electrical engineering from the Faculty of Electrical and Control Engineering of Gdańsk University of Technology. A technical and engineering specialist in the Department of System Strategy and Development. His professional interests include issues of power system operation and development of conventional and renewable energy sources, ancillary and regulation services, forecasting, and Smart Grid actions and initiatives.

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 24–30. When referring to the article please refer to the original text.

PL

## Możliwości poprawy jakości prognoz generacji wiatrowej przy wykorzystaniu dostępnych informacji jako zmiennych objaśniających

### Autorzy

Rafał Magulski  
Tomasz Pakulski

### Słowa kluczowe

prognozowanie, metody statystyczne, sieci neuronowe

### Streszczenie

Rozwój generacji wiatrowej, oprócz pozytywnych aspektów związanych z wykorzystaniem energii odnawialnej, stanowi wyzwanie z punktu widzenia bezpieczeństwa i ekonomiki funkcjonowania systemów elektroenergetycznych. Niepewny i zmienny charakter generacji źródeł wiatrowych pociąga za sobą konieczność zapewnienia przez operatora systemu przesyłowego (OSP) odpowiednich rezerw mocy, niezbędnych dla zachowania stabilnej pracy sieci, zaś podmioty zaangażowane w handel energią z tych źródeł ponoszą dodatkowe koszty bilansowania nieplanowanych odchyleń produkcji.

W artykule przedstawiono wyniki analiz dotyczących możliwości prognozowania generacji wybranej farmy wiatrowej, realizowanych za pomocą zróżnicowanych metod predykcyjnych, wykorzystujących odmienny zakres danych pomiarowych i prognostycznych, dostępnych na farmie i w jej otoczeniu. Analizy koncentrowały się na ocenie błędów uzyskiwanych prognoz oraz doborze danych wejściowych do modeli prognostycznych i ocenie ich wpływu na poprawę jakości predykcji.

### 1. Wstęp

Obecnie na świecie wykorzystuje się wiele sposobów korygowania numerycznych prognoz pogody. Najczęściej stosowana jest grupa metod statystycznych *ex post*, wykorzystujących dane historyczne. W literaturze najczęściej występującymi metodami korygowania numerycznych prognoz pogody są [1, 2, 7]:

- metody statystyczne, w których poszukuje się zależności opisujących związek zmiennych prognozowanych ze zmiennymi rzeczywistymi, np. metody regresji
- metody sztucznej inteligencji, w których w procesie uczenia wykorzystuje się korelacje pomiędzy zmiennymi wejściowymi a zmienną wyjściową (oczekiwaną), np. sztuczne sieci neuronowe (SSN).

Głównym celem przeprowadzonych badań było zbadanie możliwości korygowania numerycznych prognoz pogody w celu poprawy jakości predykcji generacji wiatrowej w horyzoncie 24-godzinowym, przy wykorzystaniu metod statystycznych oraz sztucznych sieci neuronowych [8].

Do wykonania symulacji wykorzystano historyczne dane z wybranej farmy wiatrowej. Próbkę danych wejściowych, licząca ok. 300 dni, obejmowała numeryczne prognozy pogody, pomiar rzeczywistych warunków atmosferycznych oraz wielkość rzeczywistej produkcji farmy.

Poszukiwano rozwiązania dającego w rezultacie najmniejszy średni bezwzględny błąd prognozy produkcji farmy wiatrowej NMAE<sup>1</sup>, określonego jako:

$$NMAE = \frac{MAE}{P_{FW}}$$

gdzie:

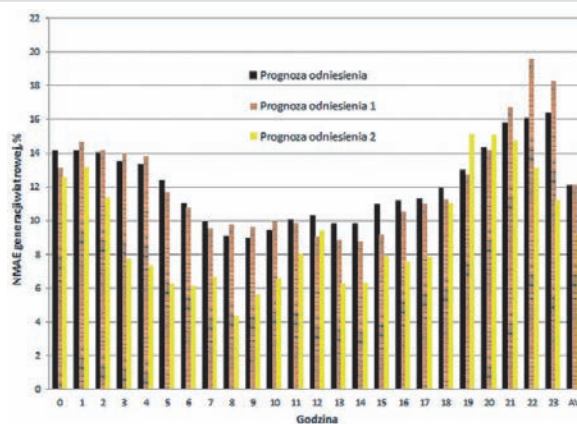
$$MAE = \frac{1}{N} \sum_{I=1}^N |PROG_I - POM_I|$$

gdzie:

$P_{FW}$  – moc znamionowa farmy wiatrowej,  
 $PROG_I$  – wartość prognozowana,  $POM_I$  – wartość pomierzona (rzeczywista),  
 $N$  – liczba próbek.

Na podstawie numerycznych prognoz pogody oraz teoretycznych krzywych mocy z poszczególnych turbin wyznaczono prognozę odniesienia produkcji farmy wiatrowej, a następnie błędy produkcji w poszczególnych godzinach doby (prognoza odniesienia).

Zbiór danych testowych wykorzystanych do wykonania symulacji za pomocą SSN został wydzielony ze zbioru głównego w sposób przypadkowy. Do testowania nauczonej sieci wybrano po kilka dni z każdego miesiąca roku (prognoza odniesienia 1)<sup>2</sup>. Zważywszy na losowy charakter wietrzności, przedstawiony dobór pod kątem błędów generacji był reprezentatywny dla całego rozpatrywanego okresu (rys. 1). W celu sprawdzenia przydatności struktur, dla których otrzymano najmniejsze błędy dla prognozy odniesienia 1, przeprowadzono alternatywne symulacje dla prognozy odniesienia 2, w której zbiór testowy obejmował wybrany ciągły 14-dniowy okres roku<sup>3</sup>. Pozostałe próbki wykorzystano w procesie uczenia.



Rys. 1. Błędy prognoz odniesienia w poszczególnych godzinach doby

<sup>1</sup> NMAE – ang. *Normalized mean absolute error*.

<sup>2</sup> Do testowania jakości nauczonej sieci wybrano 20% próbek z całego zbioru, tj. co 5 dzień.

<sup>3</sup> Dodatkowym celem przedstawionego podziału była również możliwość porównania wyników uzyskanych przy użyciu sztucznych sieci neuronowych oraz z wykorzystaniem metod statystycznych.



## 2. Poprawa jakości prognoz generacji poprzez korektę numerycznych prognoz pogody

### 2.1. Metody statystyczne

Dokonano analizy odchyłen prędkości wiatru zmierzonych na farmie wiatrowej od wielkości prognozowanych, w szczególności badając wartość oraz stacjonarność średnich odchyłen. Stwierdzono, że średnie odchylenia wielkości prognozowanych od wartości rzeczywistych są niezerowe i mają zmienny charakter, w zależności od prognozowanej prędkości wiatru. Można stąd wnioskować, że odchylenia te wykazują pewną tendencję statystyczną, której usunięcie powinno prowadzić do zwiększenia trafności prognozy wiatru, a w konsekwencji do poprawy jakości prognozy generacji farmy wiatrowej. Na tej podstawie zbudowano wiele modeli korekty prognozy wiatru, bazujących na metodzie regresji liniowej. Modele te wyznaczają zmianę wartości prognoz *ex post* w taki sposób, aby średnia ich odchyłen od wielkości zmierzonych była zbliżona do zera. W modelowaniu uwzględniono zróżnicowane okresy próbkowania danych do wyznaczania korekt, podział danych na klasy ze względu na porę doby i kierunek wiatru. Do dalszej analizy wybrano model, który w 14-dniowym okresie testowym osiągnął najmniejsze błędy prognoz prędkości wiatru.

### 2.2. Metody sztucznej inteligencji

Do wykonania symulacji zostały wykorzystane sztuczne sieci neuronowe (SSN) zawarte w pakiecie Neural Network w środowisku Matlab.

W ramach pracy testowano jednowarstwowe sieci neuronowe zbudowane na wielowarstwowym perceptronie (MLP), według zaadaptowanego algorytmu przedstawionego w [6]. Przebadano kilkadziesiąt struktur sieci dwu- oraz trójwarstwowych o zmiennej/zmiennym [3, 4]:

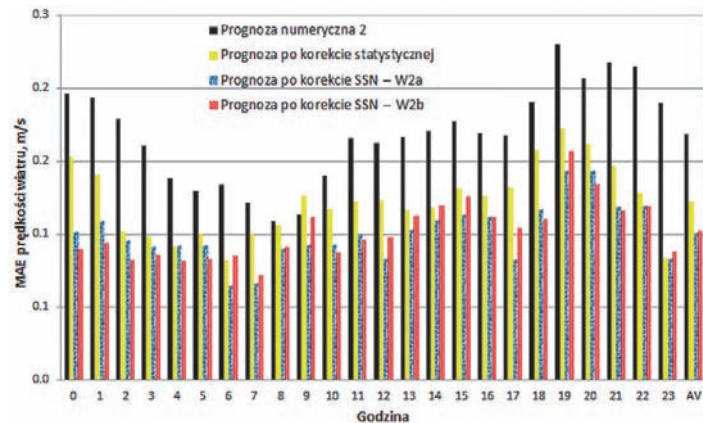
- liczbie neuronów w warstwie/warstwach ukrytych
- funkcji aktywacji neuronów w poszczególnych warstwach
- algorytmie uczenia sieci
- liczbie cykli iteracyjnych uczenia sieci.

W rozważanym wariantcie korekta prognoz produkcji była wykonywana w sposób dwuetapowy (model kaskadowy) [5]. W pierwszym etapie dokonywano korekty numerycznych prognoz pogody, które z kolei wykorzystano do wyznaczenia skorygowanych prognoz produkcji farmy. Rozpatrzono:

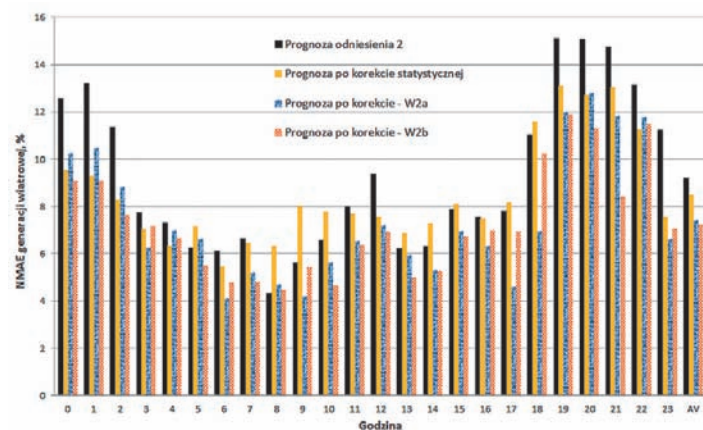
- wariant A – korekta poszczególnych zmiennych tworzących prognozę numeryczną (sieć jednowarstwowa)<sup>4</sup>.
  - wariant B – wspólna korekta numerycznej prognozy pogody (sieć wielowarstwowa)<sup>4</sup>.
- Symulacje przeprowadzono oddzielnie dla każdej godziny doby. Dla każdej godziny wybierano strukturę, dla której otrzymano najmniejsze błędy odwzorowania.

### 2.3. Porównanie wyników

Przedstawione wyniki (rys. 2) wskazują na dobową zmienność błędów prognoz.



Rys. 2. Korekta numerycznych prognoz pogody



Rys. 3. Korekta generacji wiatrowej przy wykorzystaniu skorygowanych prognoz numerycznych

Cecha	Średniobodowy błąd prognozy numerycznej MAE, m/s		Średniobodowy błąd generacji wiatrowej, NMAE, %	
	Prognoza numeryczna 1	Prognoza numeryczna 2	Prognoza odniesienia 1	Prognoza odniesienia 2
<b>Wybór struktur dających najmniejszy błąd dla poszczególnych godzin doby</b>				
Wartość przed korektą	1,71	1,69	12,2	9,2
Wartość po korekcie	1,33	1,02	10,7	7,2
<b>Redukcja błędu prognozy</b>	<b>0,38</b>	<b>0,67</b>	<b>1,5</b>	<b>2,0</b>
<b>Wybór struktury dającej najmniejszy błąd w okresie całodobowym</b>				
Wartość przed korektą	1,71	1,69	12,2	9,2
Wartość po korekcie	1,38	1,21	11,3	8,9
<b>Redukcja błędu prognozy</b>	<b>0,33</b>	<b>0,48</b>	<b>0,9</b>	<b>0,3</b>

Tab. 1. Korekta numerycznych prognoz pogody oraz generacji wiatrowej

<sup>4</sup> Przedstawione na rys. 2 i 3 wartości błędów prognoz w poszczególnych godzinach doby dotyczą struktur, dla których uzyskano najmniejszy błąd odwzorowania. AV – wartość średniobodowa.

Badania wykazały, że możliwe jest zmniejszenie błędu MAE numerycznych prognoz pogody:

- w przypadku metod statystycznych w zakresie 0,1–1,1 m/s – średnio o ok. 0,5 m/s
- w przypadku SSN w granicach 0,2–1,1 m/s – średniobowo o ok. 0,7 m/s<sup>5</sup>.

Błąd NMAE skorygowanej prognozy produkcji farmy wyznaczonej na podstawie skorygowanych prognoz numerycznych (rys. 3) zmniejszył się w stosunku do prognozy odniesienia w zależności od godziny doby:

- metody statystyczne: od –2,4% do 3,9% – średniobowo o ok. 0,7%
- sztuczne sieci neuronowe: od –0,1% do 6,3% – średniobowo o ok. 2,0%<sup>6</sup>.

Dla wybranego modelu regresji do korekty prognozy pogody średniobowy błąd prognozy prędkości wiatru wyniósł 1,2 m/s, co oznacza poprawę o ok. 0,5 m/s w stosunku do prognozy odniesienia, zaś błąd NMAE prognozy generacji, po zastosowaniu pozostałych korekt statystycznych, kształtował się na poziomie 8,5%, czyli był o ok. 0,7% niższy w stosunku do prognozy odniesienia. Wyniki uzyskane przy wykorzystaniu sztucznych sieci neuronowych zestawiono w tab. 1.

### 3. Korekta prognoz generacji wiatrowej poprzez wykorzystanie informacji o rzeczywistej produkcji


#### 3.1. Metody statystyczne

Na podstawie historycznych pomiarów wiatru oraz mocy generowanej przez poszczególne turbiny dokonano aproksymacji rzeczywistej krzywej mocy farmy wiatrowej w zależności od prędkości wiatru. Jak widać na rys. 4, uzyskana krzywa dość znacznie odbiega od krzywej wzorcowej, przyjętej jako podstawa do sporządzenia prognozy odniesienia.


Do uwzględnienia w prognozie generacji strat energii, wynikających z przesyłu i transformacji energii w obrębie farmy wiatrowej, wykorzystano sumaryczne dane o generacji poszczególnych turbin wiatrowych oraz informacje o ilości energii wprowadzanej do KSE, zmierzonej w punkcie przyłączenia farmy. Za różnicę tych wielkości odpowiadają wewnętrzne straty elektryczne farmy. Dokonując aproksymacji krzywej na podstawie danych pomiarowych (rys. 5), określono zależność strat elektrycznych na farmie od prędkości wiatru i na tej podstawie wyznaczano współczynnik korygujący energię brutto, generowaną na poszczególnych masztach do postaci energii netto, wprowadzanej do sieci.

Wykorzystano informacje o statusie poszczególnych turbin wiatrowych. Status turbiny określa jej stan pracy oraz wskazuje przyczynę w przypadku jej niedyspozycyjności. Dane historyczne o statusach turbin zostały przekształcone w taki sposób, aby mogły być traktowane jako sporządzona wcześniej prognoza dyspozycyjności farmy wiatrowej<sup>7</sup>.


Punktem wyjścia do sporządzenia prognoz generacji farmy wiatrowej były skorygowane,




Rys. 4. Aproxymacja rzeczywistej krzywej mocy farmy wiatrowej



Rys. 5. Aproxymacja krzywej korekcji o straty mocy w obrębie farmy wiatrowej



Rys. 6. Korekta generacji wiatrowej przy wykorzystaniu informacji o rzeczywistej produkcji



Rys. 7. Błędy NMAE generacji wiatrowej przed i po dokonaniu korekt

zgodnie z przyjętym modelem regresji liniowej, prognozy wiatru. Wielkość generacji obliczono na podstawie uzyskanego przybliżenia rzeczywistej krzywej mocy farmy, a następnie skorygowano ją o planowany wskaźnik dyspozycyjności farmy oraz wskaźnik strat elektrycznych na farmie.

#### 3.2. Metody sztucznej inteligencji

W rozważanym wariantcie (rys. 6) korekta prognoz produkcji była wykonywana

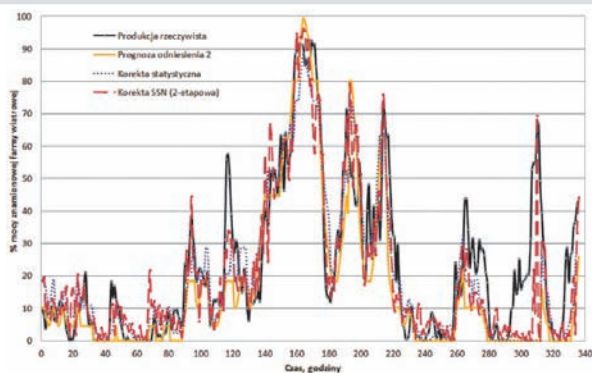
bezpośrednio na podstawie numerycznych prognoz pogody, z wykorzystaniem danych historycznych o rzeczywistej produkcji farmy oraz statusie pracy poszczególnych turbin. Wyniki symulacji przedstawionych na rys. 6 wskazują, że możliwe jest zmniejszenie błędu MAE generacji wiatrowej w zależności od godziny doby w granicach<sup>8</sup>:

- Prognoza odniesienia 1: od –0,8% do 4,5% – średniobowo o ok. 1,2% z poziomu 12,2% na 11,0%


<sup>5</sup> W obu rozpatrywanych wariantach SSN, tj. W2a i W2b, uzyskano zbliżone wyniki.

<sup>6</sup> W przypadku symulacji wykonanych dla prognozy odniesienia 2.

<sup>7</sup> Pominięto informacje o wszelkich nieprzewidywanych przerwach w pracy turbin, a uwzględniono jedynie planowane postoje, związane z prowadzonymi przeglądami, konserwacjami lub remontami. Planowane ubytki mocy w generacji farmy wiatrowej mogą posłużyć do dokonania korekty prognozy produkcji.



Rys. 8. Przebiegi generacji wiatrowej w symulowanym 14-dniowym okresie czasu



Rys. 9. Błąd prognozy generacji wiatrowej przed i po korekcie w symulowanym 14-dniowym okresie czasu

- Prognoza odniesienia 2: od -1,2% do 5,7% – średniodobowo o ok. 1,7% z poziomu 9,2% na 7,5%<sup>9</sup>.

#### 4. Porównanie jakości skorygowanych prognoz generacji

Na rys. 7 przedstawiono porównanie błędów NMAE prognozy generacji wiatrowej w poszczególnych godzinach doby, przed i po dokonaniu korekty, zaś na rys. 8 przebiegi generacji wiatrowej w symulowanym 14-dniowym okresie czasu.

Na rys. 9 przedstawiono porównanie błędów prognozy generacji wiatrowej przed i po korekcie w symulowanym 14-dniowym okresie czasu.

#### 5. Podsumowanie i wnioski

W artykule podjęto próbę poprawy jakości predykcji generacji wiatrowej poprzez korygowanie numerycznych prognoz pogody przy użyciu metod statystycznych oraz sztucznych sieci neuronowych. Badania wykazały:

- możliwość zwiększenia jakości prognozowania poprzez wykorzystanie metod sztucznej inteligencji w większym stopniu niż przy użyciu metod statystycznych
- możliwość zmniejszenia błędu MAE numerycznych prognoz pogody średniodobowo w zakresie ok. 0,5 m/s (metody statystyczne) – 0,7 m/s (SSN)

- zmniejszenie średniodobowego błędu NMAE prognozy produkcji FW wyznaczonej na podstawie skorygowanych prognoz numerycznych (korekta 2-etapowa) o ok. 1,5–2,0%<sup>10</sup>
- zmniejszenie średniodobowego błędu NMAE produkcji farmy wyznaczonej na podstawie skorygowanych prognoz numerycznych (korekta 1-etapowa) o ok. 1,2–1,7%
- zmniejszenie średniodobowego błędu NMAE produkcji farmy wyznaczonej na podstawie skorygowanych prognoz numerycznych przy użyciu metod regresji o ok. 0,4–0,7%
- preferowanie wyboru różnych struktur neuronowych do korygowania prognoz w poszczególnych godzinach doby
- składowe wykorzystane do określenia prognozy odniesienia miały tendencję do wzajemnego kompensowania generowanych przez siebie błędów (prognozy prędkości wiatru generalnie prowadziły do niedoszacowania prognozy produkcji FW, zaś skutkiem przyjęcia teoretycznej krzywej mocy było przeszacowanie produkcji), co działało na jej korzyść i mogło mieć wpływ na ograniczenie efektów zastosowanych narzędzi do poprawy jakości prognoz
- w celu poprawy jakości prognozowania przy użyciu sieci neuronowych wymagana jest ciągła aktualizacja danych

wejściowych, wykorzystywanych w procesie uczenia. Wydłużenie okresu obserwacji pracy źródeł wiatrowych do okresu wieloletnia pozwoli osiągnąć lepszą jakość predykcji.

#### Bibliografia

1. Sweeney C., Lynch P., Nolan P., Reducing errors of wind speed forecasts by an optimal combination of post-processing methods, Department of Meteorology and Climate Centre, Dublin, 2011.
2. Prondziński Z., Rubanowicz T., Zróżnicowana usługa operatora handlowo-technicznego na potrzeby rozwoju energetyki wiatrowej w Polsce, *Acta Energetica* 2004, nr 19.
3. Hernandez L., Artificial Neural Network for Short-Term Load Forecasting in Distribution Systems, *Energies* 2014, 7 1576-1598, ISSN1996-1073, marzec 2014, praca zbiorowa.
4. Perez-Llera C., Fernandez-Baizan M.C., Gonzalez del Valle V., Local Short-Term Prediction of Wind Speed: A Neural Network Analysis, Universidad Politecnica de Madrid, Spain.
5. Moghaddas-Tafreshi, S.M., Panahi D., One-hour-ahead forecasting of wind turbine power generation using artificial neural networks, University of Technology, Teheran, Iran.
6. Mao J., Zhang X., Li J., Wind power forecasting based on the BP neural network, Beifang University of Nationalities, Yinchuan, China.
7. Sweeney C. i in., Post-processing COSMO output for improved wind forecast, Meteorology and Climate Centre, University College Dublin, Ireland, April 2012.
8. Selcuk Nogay H., Akinci T.C., Eiduekiciute M., Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey, *Journal of Energy in Southern Africa*, November 2012, Vol. 23, No. 4.

<sup>8</sup> W przypadku przyjęcia struktur dających najmniejszy błąd prognozy dla poszczególnych godzin doby.

<sup>9</sup> W przypadku przyjęcia struktury dającej najmniejszy NMAE w okresie całodobowym błąd prognozy wyniósł odpowiednio: 11,3% (dla prognozy odniesienia 1) oraz 9,1% (dla prognozy odniesienia 2).

<sup>10</sup> W zależności od prognozy odniesienia.

---

**Rafał Magulski**

mgr inż.

Instytut Energetyki Instytut Badawczy Oddział Gdańsk

e-mail: r.magulski@ien.gda.pl

Absolwent Politechniki Gdańskiej Wydziału Zarządzania i Ekonomii na kierunku zarządzanie i marketing (1998). Obecnie pracuje na stanowisku starszego specjalisty inżynierijno-technicznego w Zakładzie Strategii i Rozwoju Systemu Instytutu Energetyki Oddział Gdańsk.

Jego zawodowe zainteresowania obejmują: problematykę funkcjonowania rynku w sektorze elektroenergetyki, studia przedprojektowe dotyczące rozwoju systemów energetycznych.

**Tomasz Pakulski**

mgr inż.

Instytut Energetyki Instytut Badawczy Oddział Gdańsk

e-mail: t.pakulski@ien.gda.pl

Absolwent Politechniki Gdańskiej Wydziału Elektrotechniki i Automatyki, kierunek elektrotechnika (2005). Pracuje na stanowisku specjalisty inżynierijno-technicznego w Zakładzie Strategii i Rozwoju Systemu. Jego zawodowe zainteresowania obejmują problematykę pracy systemu elektroenergetycznego oraz rozwoju klasycznych i odnawialnych źródeł energii, usługi systemowe i regulacyjne, prognozowanie, działania i inicjatywy Smart Grid.