



Energia odnawialna

Prognozowanie ilości generowanej energii elektrycznej przez elektrownie wiatrowe z wykorzystaniem sieci neuronowych

prof. dr hab. inż. Zbigniew Hanzelka
mgr inż. Mateusz Dutka
dr inż. Bogusław Świątek

Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie

Wstęp

Rynek energii pochodzącej z odnawialnych źródeł energii w Polsce rozwija się szybciej, niż zakładał to początkowo rząd oraz wymaga tego od krajów członkowskich Unia Europejska. Zgodnie z Krajowym Planem Działania w zakresie OZE w latach 2013-2014 minimalny cel dla Polski wynosił 9,54%, a w rzeczywistości elektrowni wykorzystujących OZE pracowało około 11,28% (nadwyżka 16%). Dynamiczny rozwój tego sektora energetyki spowodowany jest zdecydowanie szybszym, niż zakładano rozwojem energetyki wiatrowej. Produkcja energii w elektrowniach wiatrowych charakteryzuje się dużą zmiennością ponieważ zależna jest od czynników meteorologicznych. Zgodnie ze światowym trendem z roku na rok budowane są elektrownie o coraz większej mocy zainstalowanej turbiny i umieszczone są na jeszcze wyższych wieżach. Tego typu turbiny są bardziej opłacalne ekonomicznie, wyższe wieże pozwalają na wykorzystanie bardziej stabilnych zasobów energii wiatru, jednak mogą być również zagrożeniem dla zapewnienia stabilności systemu energetycznego w przypadku, gdy wielkość produkcji nie będzie prognozowana z odpowiednim wyprzedzeniem.

Zapewnienie stabilności systemu energetycznego oraz chęć ograniczenia strat energii wynikających z konieczności utrzymania „gorącej” rezerwy mocy jest powodem dynamicznego rozwoju dziedziny nauki specjalizującej się w prognozowaniu produkcji energii ze źródeł odnawialnych i w szczególności z wiatru.

Często stosowanymi metodami prognostycznymi są modele oparte o sztuczne sieci neuronowe. Dzięki swoim zaletom pozwalają na wygenerowanie prognoz z dużą dokładnością, pomimo, iż bazują na ogólnych, często uśrednionych danych. Ważną ich zaletą jest również duża elastyczność pod względem danych na których bazują oraz informacji jakie są w stanie na ich podstawie dostarczyć. Istotna jest również ich własność pozwalająca na możliwość szybkiej implementacji modelu do elektrowni o różnej mocy zainstalowanej, liczbie turbin, lokalizacji.

W opracowaniu zamieszczono analizy efektywności predykcji dla czterech modeli bazujących na sztucznych sieciach neuronowych dedykowanych do prognozowania produkowanej energii w śródlądowych farmach wiatrowych. Analizie poddano farmę wiatrową składającą się z 8 turbin o mocy 2,5 [MW]. Średnia roczna produkcja farmy to ponad 46 000 MWh. Park wiatrowy o łącznej mocy zainstalowanej 20 [MW]. Turbiny umieszczono na wieżach o wysokości 100 m, średnica wirnika turbiny to 100 m, a powierzchnia zataczana przez śmigła wynosi 7854 m².

Praca realizowana w ramach projektu współfinansowanego ze środków Europejskiego Funduszu Rozwoju Regionalnego Nr POiG.01.03.01-30-056/12

Wpływ czynników zewnętrznych na pracę elektrowni

Na ilość generowanej energii elektrycznej przez elektrownie wiatrową mają wpływ czynniki pogodowe oraz rozmieszczenie poszczególnych turbin. W pierwszym przypadku wynika to z praw fizyki dotyczących działania turbiny w drugim z ukształtowania terenu i zjawiska wzajemnego oddziaływania turbin na siebie - zasłaniania się turbin. Moc poruszających się mas powietrza wyraża się wzorem:

$$P_{wind} = \frac{\rho AV^3}{2} \quad (1)$$

gdzie:

P_{wind} – moc wiatru [W],

ρ – gęstość powietrza [kg/m³],

A – powierzchnia zataczana przez wirnik [m²],

V – prędkość wiatru [m/s].

Gęstość powietrza zależna jest od temperatury, ciśnienia i od ilości pary wodnej zawartej w powietrzu, zależność tą opisano wzorem:

$$\rho = \frac{pM}{RT} \quad (2)$$

gdzie:

ρ – gęstość powietrza [kg/m³],

p – ciśnienie [Pa],

M – efektywna masa molowa dla powietrza [kg/mol],

R – uniwersalna stała gazowa [J/mol*deg K],

T – temperatura [K].

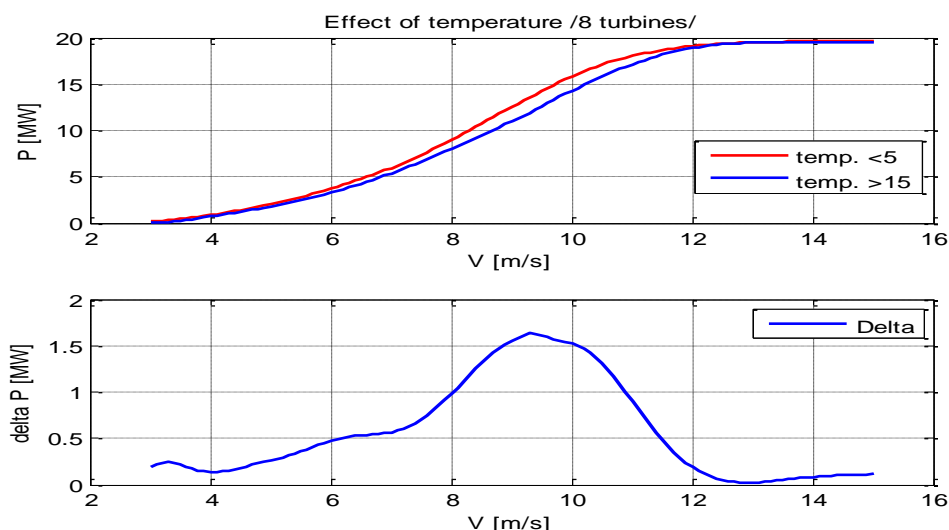
Jak wynika z zależności (1) i (2) największy wpływ na ilość generowanej energii ma prędkość wiatru oraz w mniejszym stopniu temperatura otoczenia, ciśnienie atmosferyczne oraz kierunek wiatru. Na potrzeby analizy wpływu czynników pogodowych na pracę elektrowni przygotowano sieć neuronową. Sieć posłużyła do odtwarzania krzywej mocy dla rozpatrywanych przypadków. Zbiór danych składał się z ponad 50 tysięcy wektorów danych z lat 2012-2014.

Do prognozowania produkcji w elektrowniach wiatrowych wykorzystuje się różne parametry pogodowe. Podstawowym mającym największy wpływ na jakość prognozy jest prędkość wiatru, jednak w celu poprawy dokładności predykcji wykorzystuje się dodatkowo temperaturę, ciśnienie, kierunek wiatru [3], [4]. Ciśnienie oraz temperatura są różne w zależności od wysokości co ma znaczący wpływ na przepływający strumień powietrza [5]. Przekłada się to bezpośrednio na wielkość produkcji energii w turbinach wiatrowych.

Wpływ temperatury otoczenia

Jak wynika z zależności (2) wraz ze wzrostem temperatury maleje gęstość powietrza. Zmienność temperatury w zależności od wysokości oraz jej wahania mają wpływ na przepływający przez zataczaną przez śmigła powierzchnię strumień powietrza [5]. Ma to wpływ na efektywność konwersji energii wiatru na energię mechaniczną.

Zbiór danych źródłowych podzielono na dwa podzbiory. W pierwszym umieszczono dane związane z temperaturą otoczenia $<5\text{ }^{\circ}\text{C}$, a w drugim dane dla temperatury $>15\text{ }^{\circ}\text{C}$. Temperatura w całym zbiorze zmieniała się w zakresie od $-4.7\text{ }^{\circ}\text{C}$ do $34\text{ }^{\circ}\text{C}$. Wybór granicznych temperatur pozwolił uzyskać zbiory o porównywalnej liczebności. Zawierały one odpowiednio 7365 i 7654 wektorów. Dla każdego zbioru zbudowano model neuronowy odtwarzający krzywą mocy elektrowni $P=f(v_w)$.

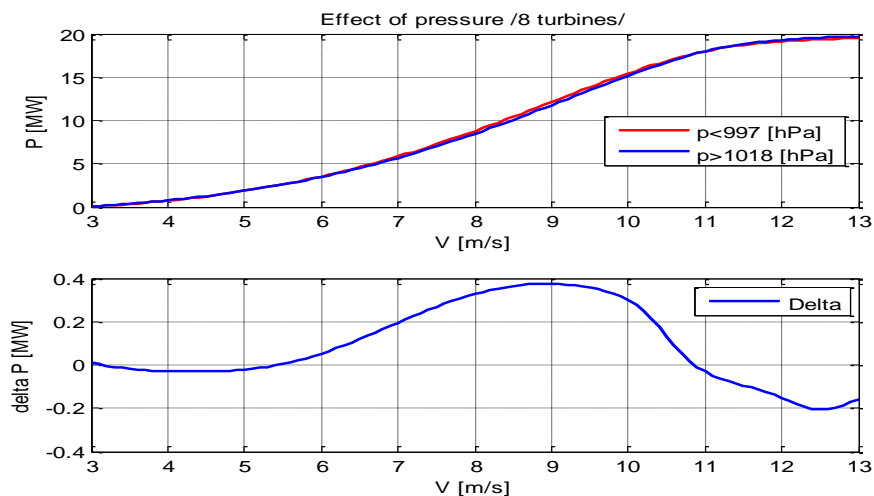


Rys. 1. Górny wykres przedstawia wyznaczoną krzywą mocy dla $T<5^{\circ}\text{C}$ i $T>15^{\circ}\text{C}$, dolny przebieg to różnica generowanej mocy dla obu przypadków.

Powyższy rysunek przedstawia wpływ temperatury na kształt krzywej mocy elektrowni. Największa różnica występuje dla wiatru wiejącego z prędkością 9,4 m/s i wynosi 1,63 MW, co stanowi ponad 8 % mocy zainstalowanej elektrowni wiatrowej.

Wpływ ciśnienia atmosferycznego

Analizę wykonano analogicznie jak w punkcie A. Wyodrębniono dwa zbiory danych. W pierwszym umieszczono dane dla ciśnienia mniejszego od 997 hPa, a w drugim dane większe od 1018 hPa. Dla obu zbiorów zbudowano model neuronowy. Wyniki uczenia sieci przedstawiono na poniższym rysunku.

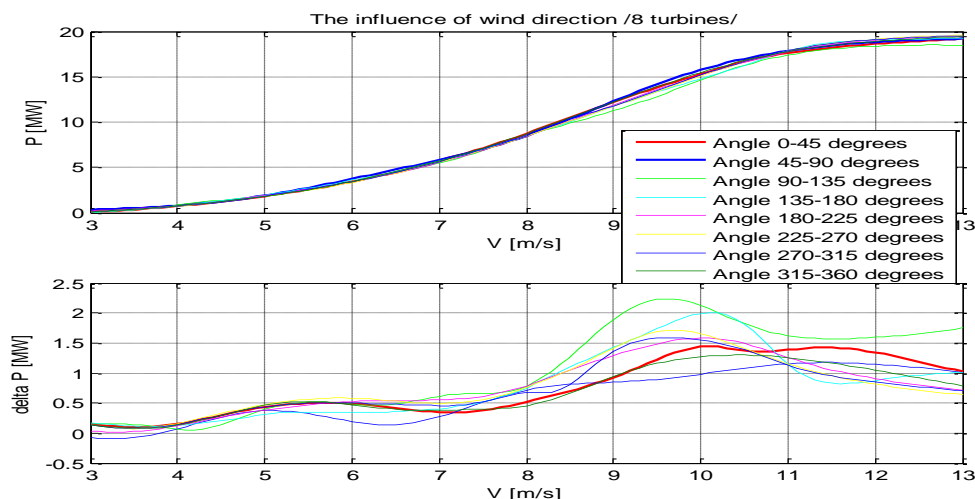


Rys. 2. Górny wykres przedstawia wyznaczoną krzywą mocy dla $p < 997$ hPa i $p > 1018$ hPa, dolny przebieg to różnica generowanej mocy dla obu przypadków.

Na rysunku 2 krzywe mocy dla obu wyodrębnionych zbiorów praktycznie się pokrywają. Różnica widoczna jest przy prędkości wiatru 9 [m/s] i wynosi niecałe 0.4 [MW]

Wpływ kierunku wiatru

Analizie poddano wpływ kierunku wiatru na przebieg krzywej mocy. Wyodrębniono osiem zbiorów danych, w których kierunek wiatru zmieniał się, co 45° i zbudowano dla nich modele sieci neuronowych. Wyniki uczenia sieci przedstawiono poniżej.




Rys. 3. Wykres przedstawia wyznaczoną krzywą mocy, dolny różnice pomiędzy deklarowaną przez producenta krzywą mocy a rzeczywistą generowaną mocą dla wybranych kierunków wiatru.

W przedziale prędkości od 3 do 8 m/s rozbieżności są małe nie przekraczające 0,7 MW, przy większych prędkościach nieco się zwiększają do ponad 2 MW. Przebiegi krzywych mocy w całym badanym zakresie się przeplatają i nie można wyróżnić jednej dominującej krzywej lub odstającej od pozostałych. Taki efekt może być skutkiem zastosowania sterowania kątem nachylenia łopatek w zależności od kierunku wiatru.

Modele sieci neuronowych

Różne struktury i typy modeli sztucznych sieci neuronowych (SSN) wykorzystywane są do prognozowania produkcji energii w farmach wiatrowych [6]. SNN mogą pracować samodzielnie lub wspólnie z innymi modelami prognostycznymi tworząc struktury hybrydowe.

W każdym przypadku zastosowano wielowarstwowe, jednokierunkowe sieci neuronowe zawierające w pierwszych dwóch warstwach neurony o sigmoidalnej funkcji przejścia oraz pojedynczy neuron liniowy w warstwie wyjściowej. Zbiór uczący zorganizowano w oparciu o dane z lat 2012-2013, tak aby obejmowały jeden pełny rok. Uczenie sieci neuronowej wykonane zostało metodą wstecznej propagacji błędów (backpropagation) z wykorzystaniem algorytmu Levenberga-Marquarda. Zaproponowane modele różnią się między sobą pod względem typu oraz liczby wejść.



Rys. 5. Schemat sieci neuronowej.

Wybór modeli prognostycznych

Badano następujące modele:

- *pfv* - model $P=f(v_w, L_t)$ - moc wyjściowa zależy od prędkości wiatru (v_w) i liczby pracujących turbin,
- *pfvt* - model $P=f(v_w, T, L_t)$ - moc wyjściowa zależy od prędkości wiatru, temp. otoczenia (T) i liczby pracujących turbin,
- *pfvtc* - model $P=f(v_w, T, C, L_t)$ - moc wyjściowa zależy od prędkości wiatru, temperatury otoczenia, ciśnienia atmosferycznego i liczby pracujących turbin,
- *pfvtcdir* - model $P=f(v_w, T, C, DIR, L_t)$ - moc wyjściowa zależy od prędkości wiatru, temperatury otoczenia, ciśnienia, wiatru (DIR) i liczby pracujących turbin.

Zbiór uczący stanowiły dane z lat 01.10.2012-30.09.2013 wybrane ze zbioru źródłowego. Dane zostały zarejestrowane przez system SCADA i są to średnie piętnastominutowe z pomiarów liczone na koniec kwadransu. Łącznie dla tego okresu zarejestrowano ponad 33 tysiące wektorów danych m.in. prędkość i kierunek wiatru, temperatura, ciśnienie.

Ponieważ w analizowanym przedziale czasu występowały okresy w których elektrownia pracowała z różną liczbą turbin, wejścia do modeli uzupełniono o ten parametr. Sytuacje te wynikały z wyłączanie niektórych turbin w celu przeprowadzenia remontu a widoczne są na Rys. 6 w postaci odgałęzień po prawej stronie krzywej mocy.

Wskaźniki oceny modeli

Ocenę efektywności modeli przeprowadzono dla okresu jednego roku poprzez porównanie:

- średni absolutny błąd prognozy MAE,

$$MAE = \frac{1}{n} \sum_t |P_{real}(t) - P_{out}(t)| = \frac{1}{n} \sum_t |e_i| \quad (3)$$

- procentowy średni absolutny błąd prognozy MAPE


$$MAPE = \frac{1}{n} \sum_t \left| \frac{(P_{real}(t) - P_{out}(t))}{P_{real}(t)} \right| \cdot 100\% \quad (4)$$

- częstotliwości uzyskiwania prognozy z dokładnością 0.5 MW i 1 MW, co stanowi $\pm 2.5\%$ i $\pm 5\%$ mocy zainstalowanej farmy wiatrowej
- absolutny błąd prognozy


$$\delta_{abs}(t) = P_{out}(t) - P_{real}(t) \text{ [MW]} \quad (5)$$

Weryfikacja modeli

W rozdziale przedstawiono wyniki predykcji produkcji energii elektrycznej dla elektrowni wiatrowej przy wykorzystaniu czterech zaproponowanych modeli prognostycznych. Weryfikacje modeli przeprowadzono przy wykorzystaniu rzeczywistych danych pogodowych (prędkość i kierunek wiatru, temperatura i ciśnienie) z okresu 01.10.2013 do 30.09.2014. Zbiór uczący oraz weryfikujący wybrano w taki sposób, aby uzyskać jeden pełny rok uwzględniający wszystkie cztery pory roku i zjawiska z nimi związane. Rzeczywistą krzywą mocy dla elektrowni wiatrowej oraz krzywe będące wynikiem prognozy dla analizowanych modeli zaprezentowano na rysunku.6.



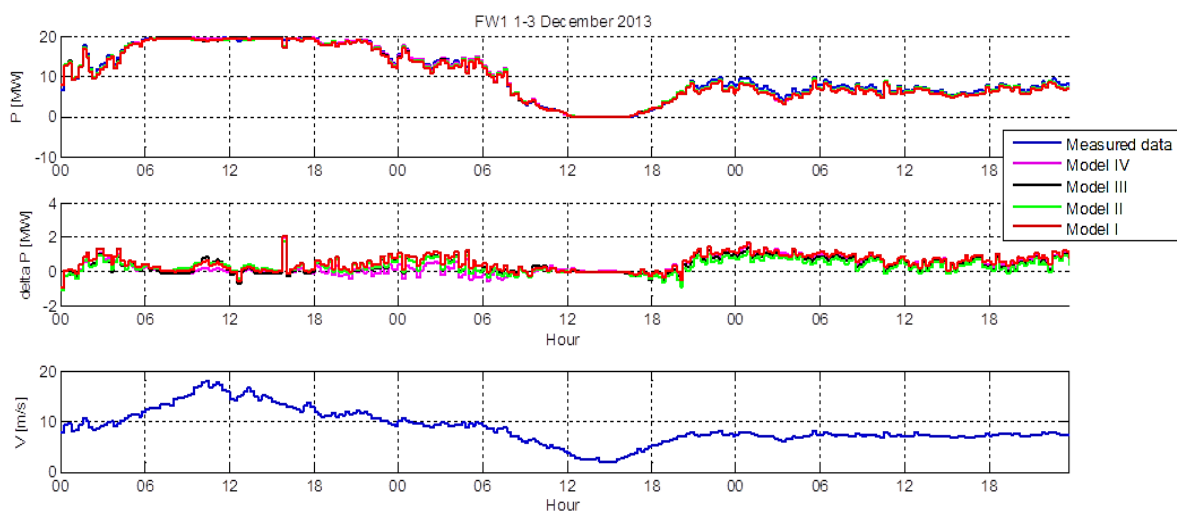
Rys. 6. Krzywa mocy farmy wiatrowej.



Rys. 7. Histogram błędów bezwzględnych dla Modeli I-IV.

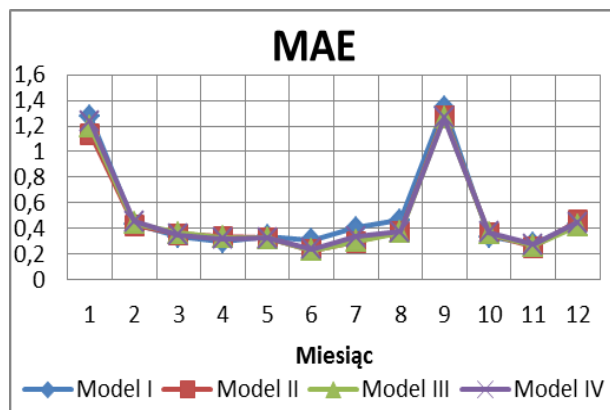
Na rysunku 7 przedstawiono histogramy błędów bezwzględnych prognozowania Modeli I-IV dla całego zbioru danych weryfikacyjnych obejmujących okres pełnego roku. Całkowita liczba wektorów danych wynosi ponad 34000. Szerokość słupka wynosi 0,2 MW dla błędów bezwzględnych.

Rysunek 8 przedstawia wyniki działania modeli w postaci przebiegów czasowych dla wybranego okresu 1-3 grudnia 2013. Okres ten charakteryzował się dużą zmiennością prędkości wiatru.

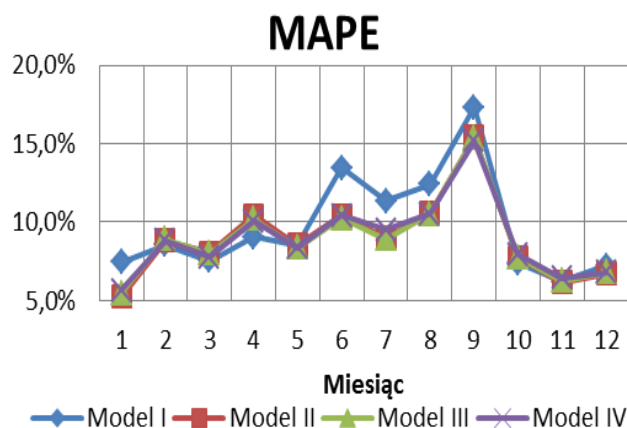


Rys. 8. Rzeczywista moc generowana, prognoza, błąd prognozy oraz prędkość wiatru dla 1-3.12.2013 i Modeli I-IV.

Wybór najlepszego modelu tzn. modelu, który z najmniejszym błędem MAE odtwarza produkcję energii w elektrowni wiatrowej wykonano dla kolejnych miesięcy danych ze zbioru weryfikującego. Wyniki zbiorcze zestawiono na rysunku.9.



Rys. 9. Zbiorcze zestawienie miesięcznych błędów MAE



Rys. 10. Zbiorcze zestawienie miesięcznych błędów MAPE

Analiza dokładności prognoz zamieszczona na rysunku 8 i 9 nie pozwala jednoznacznie wskazać dominującego modelu, który w każdym miesiącu był by efektywniejszy od pozostałych modeli. W związku z tym przeprowadzono dodatkową analizę polegającą na badaniu błędu MAPE, MAD oraz liczebności prognoz mieszczących się w błędzie $\pm 2,5\%$ oraz 5% . Wyniki zaprezentowano na Rys.10 i w Tabeli 1.

Analiza błędów MAE (rysunek. 9) wykazała występowanie dużego błędu oraz jego zmienności w wybranych miesiącach (Styczeń, Wrzesień, Grudzień). Pozostałe miesiące charakteryzowały się zdecydowanie mniejszą zmiennością błędu. Występujące duże błędy prognoz w tych miesiącach były spowodowane niejednokrotnie występowaniem silnych chwilowych podmuchów wiatru, które uaktywniały proces awaryjnego wyłączania się turbin. Rzeczywista mniejsza liczba pracujących turbin, niż wynikało by to z zarejestrowanych średnich 15 minutowych prędkości wiatru powodowała występowanie chwilowych dużych różnic pomiędzy rzeczywistą i prognozowaną prędkością wiatru.

Tabela. 1. Liczebność prognoz.

I.	II. Liczba prognoz z dokładnością [%]	
	$\pm 2,5\%$ mocy zainstalowanej	$\pm 5\%$ mocy zainstalowanej
Model I	72,36	88,99
Model II	75,97	91,28
Model III	75,46	91,17
Model IV	74,33	90,67

Wnioski

Jak wynika z przeprowadzonej analizy, widoczna jest duża zależność prędkości wiatru od produkowanej energii w elektrowni wiatrowej.

Model I wykorzystujący do prognozy prędkość wiatru i liczbę pracujących turbin do prognozowania produkcji energii okazał się być najgorszy. Charakteryzuje się największą zmiennością błędu MAPE dla poszczególnych miesięcy w roku.

Modele II i III uwzględniający dodatkowo temperaturę otoczenia oraz temperaturę i ciśnienie atmosferyczne są równorzędne i najlepsze. Uwzględniając fakt, że w badanym obiekcie ciśnienie atmosferyczne nie wpływa na prognozę można przyjąć, że najlepszym modelem jest Model II. Wyniki dla Modelu III tylko potwierdzają ten wniosek. Wizualnym potwierdzeniem tego wniosku jest też pogrubienie obliczonej krzywej mocy na Rys. 6. Modele na których wejściu jest temperatura otoczenia lepiej pokrywają zbiór danych rzeczywistych.

Dodanie na wejściu modelu kierunku wiatru powoduje pogorszenie wyników. Wynika to z fluktuacji wyników prognozy w zależności od kierunku wiatru.

Literatura

- [1] Bhaskar, M.; Jain, A.; Srinath, N.V. Wind Speed Forecasting: Present Status. In Proceedings of the 2010 International Conference on Power System Technology (POWERCON), Hangzhou, China, 24–28 October 2010; pp. 1–6.
- [2] D. Wu, H. Wang, "Application of BP neural network to power prediction of wind power generation unit in microgrid", Engineering Technology and Applications, London 2014.
- [3] Niya Chen, Zheng Qian, Xiaofeng Meng, I.T. Nabney, "Short-Term Wind Power Forecasting Using Gaussian Processes", *IJCAI 2013*, pp. 2790-2796, AAAI Press, August 2013.
- [4] M. Qi, G. P. Zhang, "Trend Time Series Modeling and Forecasting With Neural Networks", IEEE Transactions on neural networks, vol. 19, no. 5, May 2008.
- [5] M.Lange U. Focken, "Physical Approach to Short-Term Wind Power Prediction", Springer-Verlag Berlin, Heidelberg 2006
- [6] Z. Liu, W.Gao, Y.-H. Wan, E. Muljadi, "Wind Power Plant Prediction by Using Neural Network", IEEE Energy Conversion Conference and Exposition, August 2012.
- [7] Wen-Yeau Chang, "Short-Term Wind Power Forecasting Using the Enhanced Particle Swarm Optimization Based Hybrid Method", *Energies* 2013, 6, 4879-4896.