

Prognozowanie ultrakrótkoterminowe mocy generowanej w odnawialnych źródłach energii z wykorzystaniem logiki rozmytej

Streszczenie. W referacie najpierw zostały scharakteryzowane metody prognostyczne dotychczas stosowane w przypadku prognozowania ultrakrótkoterminowego mocy generowanej w elektrowniach wiatrowych oraz w elektrowniach słonecznych. Następnie została opisana koncepcja systemu do prognozowania ultrakrótkoterminowego mocy generowanej w odnawialnych źródłach energii wykorzystującego logikę rozmytą. W zakończeniu referatu dokonano jego podsumowania oraz zostały przedstawione kierunki dalszych prac badawczych w rozważanym zakresie tematycznym.

Abstract. Forecasting methods used up to now in case of very short-term prediction of power generated in wind plants and photovoltaic plants have been first characterized in the paper. Then concept of the system using fuzzy logic for very short-term forecasting of power generated in renewable energy sources has been described. At the end of the paper summary of the described issues and directions for further scientific works in the considered subject range have been presented. (*Very short-term forecasting of power generated in renewable energy sources with the use of fuzzy logic*).

Słowa kluczowe: prognozowanie ultrakrótkoterminowe, moc generowana, odnawialne źródła energii, logika rozmyta.

Keywords: very short-term forecasting, generated power, renewable energy sources, fuzzy logic.

doi:10.12915/pe.2014.06.53

Wprowadzenie

Poziom mocy generowanej przez odnawialne źródła energii (OZE), takie jak elektrownie słoneczne (ES) i elektrownie wiatrowe (EW), jest silnie uzależniony od występujących warunków atmosferycznych w miejscu ich zainstalowania.

Ze względu na przewidywany coraz większy udział OZE (EW oraz ES) w ogólnym bilansie mocy w systemie elektroenergetycznym, zagadnienia prognozowania mocy generowanej w tych źródłach nabierają coraz większego znaczenia. Prognozowanie to, w zależności od potrzeb, będzie dotyczyć różnych horyzontów czasowych. Szczególnego znaczenia, ze względu na konieczność zapewnienia bezpieczeństwa dostaw energii elektrycznej i bezpieczną pracę systemu elektroenergetycznego, nabierają prognozy o bardzo krótkich horyzontach czasowych, nazywane ultrakrótkoterminowymi (UKT).

W referacie najpierw opisano dotychczas stosowane metody prognozowania UKT mocy generowanej w EW oraz w ES. Następnie została przedstawiona koncepcja systemu do prognozowania UKT mocy wytwarzanej w tych elektrowniach z wykorzystaniem logiki rozmytej.

Podczas opracowywania referatu oparto się na wynikach zrealizowanej pracy badawczej [1].

Metody prognozowania ultrakrótkoterminowego mocy generowanej w elektrowniach wiatrowych

Obszerny przegląd metod prognozowania mocy generowanych w EW oraz metod prognozowania prędkości wiatru, w różnych horyzontach czasowych, został przedstawiony w [2].

W wymienionej pozycji literaturowej przyjęto, że horyzonty prognoz UKT dotyczących mocy wytwarzanych w EW wynoszą od kilku sekund do 30 minut naprzód.

Jeśli chodzi o metody prognozowania mocy generowanych w EW, to w [2] rozróżniono następujące techniki prognostyczne:

1. *Metodę naiwną.* Metoda ta stanowi punkt odniesienia, pod względem jakości uzyskiwanych prognoz, dla innych opracowywanych metod.
2. *Podejście statystyczne.* Podejście to opiera się na danych pomiarowych (historycznych). Rozróżnia się tu metody oparte na szeregach czasowych (najczęściej są stosowane modele: ARMA, ARIMA, ARMAX, ARX, predyktory Greya, predyktory liniowe, oraz metody

wyglądania wykładniczego) oraz metody oparte na sztucznych sieciach neuronowych - SSN (najczęściej są stosowane takie architektury SSN, jak: perceptron wielowarstwowy, sieci rekurencyjne, sieci o radialnych funkcjach bazowych, sieci liniowe).

3. *Nowe techniki prognostyczne.* Należy tu wymienić m. in.: adaptacyjne neuronowe-rozmyte systemy wnioskowania (ANFIS), systemy oparte na logice rozmytej, modele oparte na korelacji przestrzennej prędkości wiatru w różnych lokalizacjach, metody oparte na transformacji falkowej, prognozy całosciowe oraz modele z treningiem (uczeniem) opartym na entropii.

4. *Podejście hybrydowe.* W podejściu tym stosuje się połączone działanie różnych metod, np. metody opartej na szeregach czasowych łącznie z metodą opartą na SSN.

Zgodnie z informacjami podanymi w [3], obecnie głównymi metodami predykcji mocy wytwarzanej w EW są modele fizyczne i modele statystyczne. Z kolei wg informacji podanych w [4], do predykcji UKT mocy generowanej w EW są stosowane następujące modele (metody): modele fizyczne, modele statystyczne, modele oparte na korelacji przestrzennej, metody sztucznej inteligencji, modele hybrydowe łączące korelację przestrzenną prędkości wiatru ze sztuczną siecią neuronową, model hybrydowy obejmujący maszynę wektorów podtrzymujących (ang. SVM) wykorzystującą metodę najmniejszych kwadratów i filtr Kalmana.

Z przeprowadzonej w [2] oceny porównawczej wymienionych tam metod prognostycznych wynika, że w przypadku prognoz UKT najbardziej obiecujące wydaje się być obecnie stosowanie układów ANFIS, które pozwalają na wyraźną poprawę wyników prognoz o horyzoncie od kilku do kilkunastu minut naprzód, uzyskiwanych za pomocą metody naiwnej.

W przedziale czasowym prognozy UKT wiatru ważne są zarówno prędkość, jak i jego kierunek. Dlatego w [5], w celu określenia wielkości mocy generowanej, opisano prognozowanie UKT wektora wiatru, a nie prędkości wiatru lub mocy wyjściowej turbiny. W artykule tym zaprezentowano zastosowanie w celach prognostycznych systemu ANFIS.

Zaprojektowany system ANFIS [5] został zastosowany do prognoz wektora wiatru na 2,5 minuty naprzód na Tasmanii w Australii. Zastosowanie tego systemu pozwoliło uzyskać prognozy z błędem MAPE mniejszym niż 4%. Błąd

MAPE dla tego samego zadania w przypadku zastosowania metody naiwnej wynosił około 30%.

W artykule [6] zaprezentowano z kolei metodę służącą do poprawy prognozy UKT mocy generowanej przez dany turbospół wiatrowy (TZW) na podstawie informacji z numerycznej prognozy pogody (NPP) i z wielu punktów obserwacji. Punkty obserwacji odpowiadały lokalizacji sąsiednich turbin wiatrowych w obszarze danej farmy wiatrowej. Najpierw był prognozowany wektor wiatru - efektem końcowym tej procedury, w której wykorzystuje się dane z NPP, jest prognoza prędkości wiatru oraz prognoza kierunku wiatru. Następnie prędkość wiatru podlegała konwersji na moc wyjściową turbiny przy wykorzystaniu krzywej mocy. Krzywe te są zależne od kierunku wiatru i były wyznaczane lokalnie, tj. w miejscu zainstalowania turbiny.

Proponowana metoda [6] była testowana w oparciu o rzeczywiste dane pomiarowe oraz dane z NPP dla jednej farmy wiatrowej usytuowanej na Tasmanii w Australii. Uzyskane prognozy 10-minutowe mocy generowanej zostały porównane z prognozami otrzymanymi przy użyciu metody naiwnej oraz predyktora Greya, biorąc pod uwagę błędy MAE i RMSE. Błędy uzyskane dla opracowanej metody były mniejsze od błędów występujących w przypadku zastosowania metod porównawczych.

W referacie [3] do prognozowania UKT mocy generowanej w EW został zastosowany zespół sztucznych sieci neuronowych (ang. Neural Network Ensemble). W celu redukcji liczby zmiennych wejściowych (wejść sieci neuronowej) została wykorzystana metoda składowych głównych - MSG (ang. Principal Components Analysis). Jako możliwe zmienne wejściowe były rozważane: prędkość wiatru (dwie mierzone wartości), kierunek wiatru, temperatura powietrza, ciśnienie i wilgotność. Po przeprowadzeniu odpowiednich obliczeń, jako składowe główne zostały wybrane trzy pierwsze zmienne wejściowe.

Ponadto, w celu poprawy dokładności procesu uczenia, aby uniknąć zjawiska „przeuczenia się” sieci neuronowej, zespół SSN wykorzystywał algorytm ADA Boosting (wspomagania adaptacyjnego).

Przykładowe prognozy UKT zostały wykonane dla farmy wiatrowej w prowincji Zhejiang w Chinach [3]. Prognozy te były wykonywane dla okresów 10 minutowych w ciągu doby (w sumie 144 prognozy). Z wykonanych prognoz wynika, że zastosowanie MSG pozwoliło uzyskać prognozę o podobnej jakości, jak przy zastosowaniu wszystkich zmiennych wejściowych.

Dokonano porównania jakości prognoz UKT uzyskanych przez pojedynczą sieć neuronową, a także zespół sieci neuronowych. Lepszy okazał się zespół SSN - charakteryzował się on zarówno mniejszymi błędami względnymi (maksymalnym i średnim), jak i mniejszym błędem RMSE. Struktura badanej pojedynczej sieci neuronowej, jak i sieci wchodzących w skład zespołu sieci były takie same.

W referacie [4] przedstawiono z kolei zastosowanie metody opartej na modelu ARIMA szeregów czasowych do wykonywania prognoz 5 minutowych w ciągu 1 godziny (w sumie 12 prognoz). Prognozy te zostały wykorzystane w systemie wczesnego ostrzegania systemu elektroenergetycznego (działającego w trybie on-line), ze względu na bezpieczeństwo i stabilność jego działania.

Przeprowadzone zostały badania studialne na danych rzeczywistych pochodzących z farmy wiatrowej Ningxia [4]. Uzyskane wyniki prognoz porównano z wynikami uzyskanymi za pomocą metody naiwnej. Porównania dokonano dla trzech różnych przypadków: zmieniającego się trendu, gwałtownych zmian o trendzie opadającym oraz płynnych zmian o trendzie wznoszącym. W pierwszym

przypadku lepszy (ze względu na wartość błędu RMSE) okazał się model naiwny, zaś w dwóch pozostałych model ARIMA. Zaobserwowano dużą bezwładność w działaniu modelu ARIMA.

Szybkość obliczeniowa i dokładność modelu ARIMA spełniała wymagania systemu wczesnego ostrzegania działającego w trybie on-line.

W referacie [7] zaproponowano metodę prognozowania ultrakrótkoterminowego oraz krótkoterminowego pozwalającą na uzyskanie szeregu punktów (prognoz ciągłych) w określonym przedziale czasu. Zakładając brak dostępności danych z NPP, w referacie opisano zastosowanie metody klasteryzacji rozmytej do wykonania prognozy UKT.

W referacie tym zostało opisane połączenie modelu predykcji jednokrokowej z metodą klasteryzacji rozmytej, co w konsekwencji pozwoliło na ultrakrótkoterminową predykcję ciągłą (wielokrokową) mocy generowanej w EW opartą na teorii klasteryzacji rozmytej. Do ciągłej predykcji mocy generowanej został zastosowany algorytm klasteryzacji rozmytej c-średnich.

Przykładowa prognoza UKT mocy generowanej przez farmę wiatrową została oparta na danych historycznych z roku 2011 [7]. Najpierw uzyskano prognozę punktową mocy średnich na następujące: 15 minut, 1 godzinę, 2 godziny i 4 godziny naprzód przy użyciu modelu szeregów czasowych. Następnie wyznaczono prognozy wielokrokowe (ciągłe) dla każdego okresu 15 minutowego w ciągu następujących 4 godzin.

Metody prognozowania ultrakrótkoterminowego mocy generowanej w elektrowniach słonecznych

Przegląd różnych metod prognozowania mocy generowanych w ES został przedstawiony w [8].

Celem prognoz mocy generowanej przez systemy fotowoltaiczne (PV) jest oszacowanie mocy wyjściowej z określonym wyprzedzeniem czasowym, w oparciu o prognozę pogody lub inne istotne reguły odnoszące się do mocy generowanej przez te systemy [8].

Najbardziej bezpośrednią metodą prognozowania mocy generowanej przez ES jest zbudowanie modelu fizycznego paneli PV, tj. dokonanie przekształcenia nasłonecznienia na ich moc wyjściową. W tym celu najbardziej pożyteczny jest model diodowy [8]. Z drugiej strony, można również użyć metody czarnej skrzynki, tj. modelu matematycznego do zbudowania relacji zachodzących między wejściem a wyjściem modelu. Metoda ta jest oparta na wartościach mocy generowanej w przeszłości, do predykcji przyszłości, tj. trendu mocy wyjściowej. Aby uwzględnić wpływ warunków pogodowych, prognozowane zmienne pogodowe, uzyskane z NPP, są zawsze używane jako dane wejściowe tego modelu. W modelach tych są stosowane takie metody prognostyczne jak [8]: metoda naiwna, metody autoregresji oraz sztuczne sieci neuronowe.

Jeśli chodzi o horyzont prognozy, to w pracy [8] uznano, że prognozy UKT, to prognozy z wyprzedzeniem rzędu kilku minut do kilku godzin.

W artykule tym zostały przedstawione dwie metody prognozowania mocy generowanej przez ES: metoda oparta na modelu fizycznym oraz metoda statystyczna wykorzystująca SSN. Zaprezentowano wpływ danych wejściowych, takich jak nasłonecznienie, temperatura powietrza, zachmurzenie, wilgotność i pozycja słońca na dokładność prognozy. Określono również zestaw najlepszych danych wejściowych. Dokonano porównania działania obu metod prognostycznych na przykładzie ES o mocy 1 MW, zawierającej ponad 6 tysięcy paneli PV [8]. Błąd prognozy nRMSE za okres jednego miesiąca był nieco mniejszy w przypadku stosowania SSN. Ustalono również,

że błędy nRMSE zależały od pory roku. Jako główne źródło błędów prognoz autorzy pracy [8] uznali niewystarczającą dokładność informacji pochodzących z NPP. Aby poprawić jakość prognoz UKT, autorzy wymienionej pracy proponują użycie zmierzonego w czasie rzeczywistym nasłonecznienia jako wejścia do modelu.

W przypadku modelu fizycznego przetestowano dwa przypadki: gdy danymi wejściowymi były dane z NPP oraz gdy danymi wejściowymi były dane pomiarowe (nasłonecznienie i temperatura). Błędy nRMSE były o wiele mniejsze w drugim testowanym przypadku. Jeśli chodzi o sieć SSN, to najmniejsze błędy uzyskano wtedy, gdy na wejście sieci zostały podane dane o temperaturze powietrza, nasłonecznieniu, współczynniku zachmurzenia, wilgotności i pozycji słońca.

W artykule [9] zostały z kolei przedstawione dwie metody prognozowania produkcji energii elektrycznej w systemach PV: metoda oparta na modelu fizycznym panelu PV oraz SSN typu perceptron wielowarstwowy. W modelu fizycznym uzależniono prognozę godzinową produkcji energii (średnią moc godzinową) od prognozy nasłonecznienia oraz prognozy średniej temperatury powietrza.

Weryfikacja jakości działania obu wymienionych metod prognozowania została dokonana na przykładzie zestawu paneli PV o mocy około 19,5 kW [9]. Dostępne były dane historyczne dotyczące godzinowej produkcji energii. Jako prognozowane dane pogodowe przyjęto: temperaturę powietrza, nasłonecznienie, ciśnienie powietrza, zachmurzenie, prędkość wiatru, kierunek wiatru oraz wielkość opadów. Do oceny jakości prognoz posłużono się wartością błędu nRMSE. W przypadku metody opartej na modelu fizycznym zaobserwowano przeszacowanie prognozy w stosunku do rzeczywistych wartości wytwarzanej energii. Dobowy błąd nRMSE był dla niej ponad dwukrotnie większy niż dla SSN przy prognozie na godzinę naprzód. Wartość błędu nRMSE dla metody naiwnej (opierającej się na modelu Markowa) była trochę mniejsza niż dla metody opartej na modelu fizycznym.

Koncepcja systemu do prognozowania ultrakrótkoterminowej mocy generowanej w elektrowniach wiatrowych oraz elektrowniach słonecznych z wykorzystaniem logiki rozmytej

Przedstawia się koncepcję systemu służącego do prognozowania mocy wytwarzanej w EW oraz ES opartą na systemach rozmytych typu 2, opisaną w [1].

Systemy rozmyte typu 2 (T2 FLS) używają zbiorów rozmytych typu 2 (T2 FS). Te ostatnie charakteryzują się trójwymiarowymi funkcjami przynależności (FP), które zawierają ślad niepewności [10]. Ślad niepewności i trzeci

wymiar FP dostarczają dodatkowych stopni swobody, co powoduje, że T2 FLS mogą sobie dobrze radzić z niepewnymi informacjami. Dlatego uznaje się [11], że T2 FLS powinny działać lepiej od systemów rozmytych typu 1 (T1 FLS).

Zbiory rozmyte typu 2 zostały wprowadzone przez Zadeha [12] jako rozszerzenie zbiorów rozmytych typu 1. Struktura reguł rozmytych oraz sposób wnioskowania w systemach T2 FLS są podobne do tych, które występują w systemach T1 FLS. Struktura rozmytego systemu wnioskującego typu 2 została pokazana na rysunku 1. W bloku redukcji typu dochodzi do konwersji zbiorów rozmytych typu 2 na zbiory rozmyte typu 1.

Ze względu na złożoność obliczeniową systemów T2 FLS, w praktyce często są stosowane (patrz np. [10]) przedziałowe systemy rozmyte typu 2 (IT2 FLS) [14], charakteryzujące się mniejszym wysiłkiem obliczeniowym procesu wnioskowania.

Systemy IT2 FLS są narzędziami potrafiącymi poprawić dokładność prognoz [10]. Przeprowadzone eksperymenty na rzeczywistych zbiorach danych pokazały, że systemy IT2 TSK FLS (z modelem wnioskowania Takagi-Sugeno-Kanga) potrafią dokładnie aproksymować przyszłe zapotrzebowanie na moc z akceptowalną dokładnością.


W formułowanej w tym punkcie koncepcji, opartej na pracy [1], założono, że do prognozowania UKT mocy generowanej w poszczególnych TZW (znajdujących się w farmie wiatrowej) oraz w ES zostanie wykorzystany system IT2 FLS.

Podczas budowy takiego systemu konieczne będzie rozwiązanie następujących problemów:

- wybór klasy modelu,
- wybór liczby zbiorów rozmytych (funkcji przynależności) dla każdego wejścia,
- wybór postaci funkcji przynależności dla reguł rozmytych,
- określenie rodzaju śladu niepewności,
- wybór liczby i rodzajów wejść,
- wybór algorytmu redukcji typu,
- określenie algorytmu uczenia systemu IT2 FLS.

Zasadniczo, szczegółowym badaniom należałoby poddać dwie klasy przedziałowych systemów rozmytych typu 2, a mianowicie: IT2 FLS oraz IT2 TSK FLS. Ta druga klasa wymaga mniejszej liczby parametrów modelu i w ten sposób wydaje się łatwiejsza do zastosowania.

Funkcje przynależności mogą być np. typu Gaussa lub trapezoidalne. Dla systemu IT2 TSK FLS konieczne będzie również zdefiniowanie zależności funkcyjnych dla następników poszczególnych reguł – zwykle są to zależności liniowe.



Rys. 1. Struktura rozmytego systemu wnioskującego typu 2 [1]; opracowano na podstawie [10, 13]

Jeśli chodzi o ślad niepewności, to w przypadku często stosowanej funkcji typu Gaussa może nim być: zmienna wartość średnia, zmienne odchylenie standardowe, czy zmienna wartość średnia i zmienne odchylenie standardowe.

Do redukcji typu proponuje się zastosować algorytm Karnika-Mendela (KM), który przekształca zbiory rozmyte T2 FS na zbiory rozmyte T1 FS, używając w tym celu koncepcji centrów zbiorów [15].

Bardzo istotną sprawą jest wybór liczby i rodzajów wejść. W przypadku prognoz UKT mocy generowanych przez TZW, proponuje się zastosować dwa wejścia, z których jedno będzie stanowiło prognozę prędkości wiatru, zaś drugie prognozę kierunku wiatru. Obie prognozy powinny pochodzić z miejsca lokalizacji turbiny wiatrowej.

W procesie uczenia projektowanego systemu, pozwalającego określić wartości jego poszczególnych parametrów, proponuje się zastosować algorytm ewolucyjny (jak opisano w [10]) lub algorytm PSO (ang. Particle Swarm Optimization). W procesie tym powinny być dostępne dane historyczne na temat warunków pogodowych (prędkość wiatru, kierunek wiatru) w miejscu lokalizacji rozważanej turbiny wiatrowej oraz odpowiadające im dane o mocy generowanej przez analizowany turbospół.

Jeśli chodzi o wybór liczby i rodzajów wejść w przypadku prognoz UKT mocy generowanych przez ES, to proponuje się zastosować pięć wejść, obejmujących następujące dane prognozowane: nasłonecznienie, temperatura powietrza, wskaźnik zachmurzenia, wilgotność, pozycja słońca. Wszystkie prognozowane wielkości powinny pochodzić z miejsca lokalizacji elektrowni słonecznej.

W procesie uczenia systemu powinny być dostępne dane historyczne na temat wszystkich wymienionych powyżej danych pogodowych w miejscu lokalizacji rozważanej ES oraz odpowiadające im dane o mocy generowanej przez tę elektrownię.

Przewiduje się, że poprawnie zaprojektowany system IT2 FLS pozwoli na wykonywanie prognoz UKT mocy generowanej przez TZW lub ES z wyprzedzeniem czasowym wynoszącym od kilku minut do kilku godzin.

Podsumowanie

Sporządzanie dokładnych prognoz UKT mocy wytwarzanej w odnawialnych źródłach energii (EW i ES) jest istotnym wyzwaniem badawczym i praktycznym.

W referacie opisano kilka dotychczas stosowanych metod prognozowania mocy generowanej w tego typu elektrowniach, a następnie przedstawiono koncepcję systemu do prognozowania UKT mocy wytwarzanej w OZE, z wykorzystaniem systemów rozmytych.

Zdefiniowane zostały problemy, które trzeba rozwiązać podczas budowy systemu typu IT2 FLS do prognozowania UKT mocy wytwarzanej w OZE, a także przedstawiono uwagi realizacyjne, dotyczące prognozowania mocy generowanej w EW oraz ES. Założono, że projektowany system pozwoli na wykonywanie prognoz UKT mocy generowanej z wyprzedzeniem czasowym wynoszącym od kilku minut do kilku godzin.

Dalsze prace w omawianym zakresie tematycznym powinny dotyczyć badań aplikacyjnych związanych z: budową systemu IT2 FLS do prognozowania UKT, opracowaniem prognoz w oparciu o dane rzeczywiste, a także oceną jakości uzyskiwanych prognoz.

Praca została wykonana w ramach projektu 4RES realizowanego przez Globema Sp. z o. o. we współpracy z Instytutem Elektroenergetyki Politechniki Warszawskiej, współfinansowanego przez Narodowe Centrum Badań i Rozwoju w ramach programu INNOTECH.

LITERATURA

- [1] Baczyński D., Helt P., Parol M., Piotrowski P., Wasilewski J., Wójtowicz T., Kopeć J., Wędołowski K.: Opracowanie modeli i algorytmów ultrakrótkoterminowego prognozowania produkcji energii elektrycznej w odnawialnych źródłach energii. Instytut Elektroenergetyki PW. Praca na zlecenie Globema Sp. z o.o., 2012
- [2] Soman S. S., Zareipour H., Malik O., Mandal P.: A Review of Wind Power and Wind Speed Forecasting Methods With Different Time Horizons. *Proceedings of the 42nd North American Power Symposium (NAPS 2010)*, 26-28 September, Arlington, Texas, USA
- [3] He D., Liu R.: Ultra-short-term Wind Power Prediction Using ANN Ensemble Based on PCA. *Proceedings of the 7th International Power Electronics and Motion Control Conference - ECCE Asia*, June 2-5, 2012, Harbin, China
- [4] Kang Ch., Yong Ch., Feng X., Chuanzhi X., Xiaofang S., Dongkuo S., Maosheng D., Jun Z., Li X., Jiafeng S., Xiaoyu L.: Ultra-short-term Wind Power Prediction and Its Application in Early-warning System of Power Systems Security and Stability. *Proceedings of the 4th IEEE International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT)*, 6-9 July, 2011, Weihai, China
- [5] Potter C. W., Negnevitsky M.: Very Short-Term Wind Forecasting for Tasmanian Power Generation. *IEEE Transactions on Power Systems*, Vol. 21, No. 2, May 2006, pp. 965 – 972
- [6] Khalid M., Savkin A. V.: A Method for Short-Term Wind Power Prediction With Multiple Observation Points. *IEEE Transactions on Power Systems*, Vol. 27, No. 2, May 2012, pp. 579 – 586
- [7] Wei W., Zhang Y., Wu G., Tong M.: Ultra-short-term/Short-term Wind Power Continuous Prediction Based on Fuzzy Clustering Analysis. *Proceedings of the IEEE Innovative Smart Grid Technologies – Asia (ISGT Asia)*, 21-24 May, 2012, Tianjin, China
- [8] Huang Y., Lu J., Liu Ch., Xu X., Wang W., Zhou X.: Comparative Study of Power Forecasting Methods for PV Stations. *Proceedings of the International Conference on Power System Technology (POWERCON 2010)*, 24-28 October, 2010, Zhejiang, Hangzhou, China
- [9] Wasilewski J., Baczyński D.: Krótkoterminowe prognozowanie produkcji energii elektrycznej w systemach fotowoltaicznych. *Rynek Energii*, Nr 5 (96), 2011, str. 47 – 51
- [10] Khosravi A., Nahavandi S., Creighton P., Srinivasan D.: Interval Type-2 Fuzzy Logic Systems for Load Forecasting: A Comparative Study. *IEEE Transactions on Power Systems*, Vol. 27, No. 3, August 2012, pp. 1274 – 1282
- [11] Hagrass H.: A hierarchical type-2 fuzzy logic control architecture for autonomous mobile robots. *IEEE Transactions on Fuzzy Systems*, Vol. 12, No. 4, 2004, pp. 524 – 539
- [12] Zadeh L.A.: The concepts of a linguistic variable and its application to approximate reasoning. Parts 1-3, *Information Sciences*, No. 8, pp. 199-249; No.8, pp. 301-357; No. 9, pp. 43-80; 1975
- [13] Rutkowski L.: *Metody i techniki sztucznej inteligencji*. Wydanie 2. PWN, Warszawa 2009
- [14] Liang Q., Mendel J.M.: Interval type-2 fuzzy logic systems: Theory and design. *IEEE Transactions on Fuzzy Systems*, Vol. 8, No. 5, 2000, pp. 535 – 550
- [15] Karnik N.N., Mendel J.M.: Centroid of a type-2 fuzzy set, *Information Sciences*, Vol. 132, No. 1-4, February 2001, pp. 195 – 220

Autor: dr hab. inż. Mirosław Parol, Politechnika Warszawska, Instytut Elektroenergetyki, ul. Koszykowa 75, 00-662 Warszawa, E-mail: miroslaw.parol@ien.pw.edu.pl;