

Problematyka prognoz generacji wiatrowej w KSE

Streszczenie. Od kilkunastu lat udział energetyki odnawialnej w sektorze elektroenergetyki stale rośnie. Przyczyny tego stanu rzeczy są różne: wyczerpywanie się paliw kopalnych, proekologiczna polityka UE, awarie elektrowni atomowych na świecie, które wzbudzają w społeczeństwie uczucie niepokoju oraz wiele innych skutkujących wzrostem udziału OZE w ogólnym bilansie produkcji energii elektrycznej. Większa liczba nowych źródeł energii elektrycznej, w szczególności farm wiatrowych, powoduje nowe problemy związane z prognozowaniem poziomu produkcji energii. Elektrownie wiatrowe są urządzeniami, które nie zapewniają stabilnego poziomu dostaw energii. Dlatego istnieje potrzeba opracowania modeli prognostycznych, które umożliwiają prognozowanie pracy takich jednostek w KSE w sposób rzetelny. W artykule podjęto próbę zastosowania teorii fraktalnej analizy procesów związanych z eksploatacją elektrowni wiatrowych do poprawy dokładności prognoz. Opisano wyniki badań i sugestie dotyczące ich możliwości zastosowania.

Abstract. Since several years the percentage of renewable power engineering in the sector of electric power engineering constantly grows. The reasons for this state are various: depletion of fossil fuels, breakdowns of atom power stations, which cause the feeling of anxiety, strong pro-ecological tendencies in EU as well as the possibility to make the country independent on others. A higher number of new sources of electric energy, in particular wind farms, causes new problems related to forecasting the energy production level. Wind power stations are units, which do not provide a stable level of energy supply. Therefore there exists a need to develop forecasting models, which make it possible to forecast the work of such units in Polish Power System in a reliable way. In the paper an attempt has been undertaken to apply the theory of fractal analysis to the processes related to the operation of wind power stations for improving the accuracy of forecasts. Research results and suggestions concerning their further possible applications have been given. (**Forecast wind generation problem in Polish Power System**)

Słowa kluczowe: Modelowanie, prognozowanie krótkoterminowe, wykładnik Hursta.

Keywords: Modeling, short-term forecasting, Hurst exponent.

doi:10.12915/pe.2014.07.23

Wprowadzenie

Od kilkadziesiąt lat w UE trwają ciągłe prace nad rozwojem technologii produkcji energii elektrycznej z wykorzystaniem zasobów odnawialnych. Obecnie technologie te są na tyle zaawansowane, że możliwe jest ich powszechne stosowanie i włączanie w system elektroenergetyczny. Jednym z najdynamiczniej rozwijających się odnawialnych źródeł energii jest energetyka wiatrowa. W ostatnim dziesięcioleciu roczny przyrost mocy nominalnej powstających instalacji wynosi przynajmniej kilkadziesiąt procent [12]. Ze względu na swój charakter źródła wykorzystujące energię wiatru cechują się dużą niestabilnością uzależnioną od czynników pogodowych. Stopniowe zwiększanie udziału energetyki wiatrowej w systemie elektroenergetycznym powoduje problemy związane z ciągłością i stabilnością wytwarzania energii elektrycznej. Dlatego niezmiernie istotnym problemem staje się przewidywanie produkcji energii generowanej przez energetykę wiatrową, zarówno w skali mikro (pojedyncze farmy, turbozespoły wiatrowe) jak i makro (energia dostarczana do systemu elektroenergetycznego przez wszystkie źródła wiatrowe).

Analizując literaturę z ostatnich kilkadziesiąt lat związaną z prognozowaniem pracy elektrowni wiatrowych można zaobserwować gwałtowny rozwój metod prognostycznych dedykowanych temu problemowi. Prym w tej dziedzinie wiodą ośrodki naukowe zlokalizowane w zachodnich krajach Europy. Powstające modele predykcyjne są wykorzystywane przez operatorów systemów elektroenergetycznych co powoduje, że w publikacjach naukowych przedstawiane są jedynie wyniki badań zaś same narzędzia chronione są poprzez licencje lub patenty. Powstałe metody można podzielić na dwie zasadnicze grupy przedstawiające odmienny sposób podejścia do problemu. Pierwsza skłania się ku statystycznemu ujęciu problematyki prognostycznej. Wykorzystuje się dane historyczne związane z pracą elektrowni wiatrowej i jej otoczeniem, a następnie szuka się różnorodnych związków umożliwiających przewidywanie mocy generowanej w elektrowni wiatrowej na bazie historycznych relacji. Druga, grupa metod reprezentuje

podejście fizyczne. Twórcy modeli fizycznych starają się jak najdokładniej odwzorować warunki fizyczne, którym podlega badany obiekt by dopiero w końcowej fazie użyć właściwego narzędzia predykcyjnego. Nie jest to podział ścisły i ostateczny. Z biegiem lat powstają kolejne metody, w których wykorzystuje się oba podejścia jednocześnie, tworzone są modele hybrydowe i skomplikowane systemy, których ostatecznym efektem ma być jak najdokładniejsza prognoza.

W najbliższym czasie również operator polskiego systemu elektroenergetycznego stanie przed problemem szacowania wielkości energii pozyskiwanej poprzez energetykę wiatrową w ogólnym bilansie energetycznym. Zasadnym zatem jest zajęcie się tą tematyką i poszukiwanie nowych, przynoszących oczekiwany efekt narzędzi prognostycznych.

Zastosowanie modelu MRK do prognozy mocy elektrowni wiatrowej

Prognozowanie zapotrzebowania na moc lub energię elektryczną w skali makro dla krajowego systemu elektroenergetycznego lub lokalnych systemów jest zagadnieniem w miarę rozpoznanym i dość szeroko opisanym w literaturze [1,2,3,5,6,7]. Gorzej jest w przypadku prognozowania i modelowania dla potrzeb „energetyki wiatrowej”. Jest to zagadnienie nowe, które wymaga specyficznego podejścia uwzględniającego charakter tych procesów i nie ma zbyt wielu opracowań oraz zweryfikowanych metod umożliwiających predykcję mocy farmy wiatrowej. Najczęściej autorzy zajmujący się tymi zagadnieniami sięgają do własnych pozytywnych doświadczeń zdobytych w innych obszarach, aby zaimplementować je lub zweryfikować ich poprawność w nowej rzeczywistości.

Prace naukowe Zakładu Urządzeń i Gospodarki Elektroenergetycznej Politechniki Częstochowskiej skutkowały opracowaniem modelu rozkładu kanonicznego wektora zmiennych losowych (MRK), który wielokrotnie był wykorzystywany do prognoz i szczegółowo opublikowany w monografiach oraz renomowanych czasopismach naukowych [2,5,6,7]. Model ten między innymi wdrożono w

PSE Operator S.A. i wykorzystuje się do prognoz obciążeń w krajowym systemie elektroenergetycznym. W artykule opisano proces implementacji tego modelu dla potrzeb prognozy obciążeń dla farmy wiatrowej rozbudowanej o elementy chaosu zdeterminowanego w celu wykorzystania samopodobieństwa procesów do poprawy dokładności modelu.

Podstawy teoretyczne MRK

Zakłada się, że pewien proces opisany jest wektorem losowym \mathbf{X} , którego składowe x_i ($i = 1, 2, \dots, m$) są ze sobą skorelowane. Wektor \mathbf{X} o składowych skorelowanych przekształca się na inny wektor \mathbf{V} , o składowych nieskorelowanych. Uzyskane składowe są funkcjami liniowymi składowych wektora \mathbf{X} .

W ogólnym przypadku stosowania modelu MRK w procesie prognozy wybieramy przypadek, w którym znamy realizacje p składowych, a prognozujemy $(m-p)$ zmiennych. W prognozie zmienne X_1, X_2, \dots, X_p są traktowane jak zmienne objaśniające, składowe X_{p+1} i dalsze są zmiennymi endogenicznymi. Równanie dla wyznaczenia prognozy i -tej składowej (zmiennej) jest następujące:

$$(1) \quad \hat{Y}_i = \sum_{j=1}^{i-1} a_{ij} V_j + \hat{V}_i + \bar{x}_{X_i}$$

Rozpisując równanie (1) w każdym kolejnym równaniu nieznaną pozostaje wartość \hat{V}_i , której wartość wynika z ogólnej zależności:

$$(2) \quad V_i = f_1(X_{01}, X_{02}, \dots, X_{0i})$$

W praktyce modelowania z zależności (2) nie można by było skorzystać ze względu na brak korelacji pomiędzy zmiennymi objaśniającymi. Jednakże kolejne wektory V_i można wyznaczyć wykorzystując dane historyczne poprzez konstrukcję empirycznych warunkowych rozkładów częstości, a na ich podstawie dystrybuant o następującej postaci:

$$(3) \quad \begin{aligned} & F_1(v_2 | V_1 < v_1) \\ & F_2(v_3 | V_1 < v_1, V_2 < v_2) \\ & \dots \\ & F_{m-1}(v_m | V_1 < v_1, V_2 < v_2, \dots, V_{m-1} < v_{m-1}) \end{aligned}$$

W zastosowaniu praktycznym uwzględniając związki (3), buduje się funkcje gęstości prawdopodobieństwa wg następującej ogólnej formuły:

$$(4) \quad F_i(V_{i+1} | x_{0igr} < X_{0i} \leq x_{0ig,r+1}), \quad i = 1, 2, \dots, m-1$$

Pełny opis procedur rozkładu kanonicznego wraz z ich szczegółowym zastosowaniem w procesie predykcji zamieszczono w monografiach [2,5,6].

Wykorzystanie geometrii fraktalnej do opisu szeregów czasowych generowanych na farmie wiatrowej


Przez setki lat matematyka nie była w stanie opisać zjawisk zachodzących w przyrodzie. Wydawały się one zbyt skomplikowane. Dopiero kilkadziesiąt lat temu zaczęła się rozwijać nowa dziedzina, dająca nowe spojrzenie i opis procesów tzw. samopodobnych w przyrodzie. Geometria fraktalna stała się impulsem dla wielu naukowców by na nowo przyjrzeć się wielu problemom, które dotąd nie znalazły rozwiązania. Podstawowym pojęciem tego

kierunku nauki jest fraktal. Obecnie nie ma ścisłej definicji tego obiektu. Za [4] można przytoczyć, iż jest to obiekt, którego części pozostają w pewnej relacji do całości. Fraktal jest również określany jako zbiór posiadający określone cechy [4,8]:

- ma nietrywialną strukturę w każdej skali,
- struktura ta nie daje się łatwo opisać w języku tradycyjnej geometrii euklidesowej,
- jest samopodobny, jeśli nie w sensie dokładnym, to przybliżonym lub stochastycznym,
- jego wymiar fraktalny jest większy niż jego wymiar topologiczny,

Można zaobserwować dwa typy fraktali [8]:

- deterministyczne (tworzone za pomocą pewnej reguły, zbiór Cantora, krzywa Kocha, zbiór Mandelbrota, zbiory Julii),
- losowe (linia brzegowa, drzewo, płuca)



Rys.1. Etapy tworzenia trójkąta Sierpińskiego.

Fraktale deterministyczne czyli matematyczne są obiektami symetrycznymi i samopodobnymi w dowolnej skali. Są one generowane poprzez wzory rekurencyjne lub system funkcji iterowanych (IFS – iterated function system). Fraktale losowe powstają na skutek losowego wybierania tworzących go reguł w różnych skalach. Obiekty takie mogą wykazywać się samopodobieństwem o ograniczonym zakresie ze względu na czynnik losowości wpływający na ich tworzenie.

Jednym z podstawowych elementów charakteryzujących fraktal jest jego wymiar. Mówi on nam w jaki sposób dany obiekt wypełnia swoją przestrzeń. W analizie fraktalnej należy zwracać uwagę aby porównując wymiary różnych obiektów sposób ich wyznaczania był ten sam. Zapewni to prawidłową oceną badanych cech obiektów. Poniżej przedstawiono najczęściej występujące wymiary[10]:

- Hausdorffa
- samopodobieństwa
- pudełkowy
- pojemnościowy
- informacyjny
- wymiar euklidesowy
- cyrklowy

Każdy z nich niesie pewną informację o obiekcie. W zależności od badanego elementu, wartości poszczególnych wymiarów różnią się lecz czasem ich wartości mogą się pokrywać. Przedstawione powyżej cechy i własności można zastosować w badaniach szeregów czasowych. Można go porównać do linii brzegowej. Im większe powiększenie zostanie zastosowane w trakcie analizy linii brzegowej, tym więcej szczegółów można zauważyć. Podobna sytuacja zachodzi w przypadku szeregów czasowych, gdy bierzemy pod uwagę coraz krótsze odcinki czasu.

Badając szeregi czasowe można zaobserwować bardzo istotną właściwość – samopodobieństwo o charakterze statystycznym. Szeregi czasowe przejawiające zaprezentowane cechy nazywane są szeregami fraktalnymi [4]. Warto dodać, że szeregi takie cechują się występowaniem długoterminowej korelacji. Zatem zasadne jest wyznaczenie wymiaru fraktalnego takiego przebiegu. Najczęściej wykonuje się to poprzez zbadanie stopnia postrzępienia wykresu. Można to wykonać stosując metodę graficzną wychodząc z definicji określającej wymiar cyrkłowy lub pudełkowy. W dalszej części artykułu zdecydowano się wykorzystać wykładnik Hursta celem ustalenia wymiaru fraktalnego badanych szeregów czasowych oraz wykorzystania jego właściwości do poprawy dokładności krótkoterminowych prognoz mocy generowanej przez farmę wiatrową.

Metodyka wyznaczania wykładnika Hursta

Istnieje związek między wymiarem fraktalnym szeregu czasowego, a wykładnikiem Hursta. Wyrażony jest on zależnością [4]:

$$(5) \quad D = 2 - H$$

gdzie: D – wymiar fraktalny, H – wykładnik Hursta

Korzystając z równania (5) można wyznaczyć wymiar fraktalny badanego szeregu czasowego poprzez wyznaczenie wartości wykładnika. Nazwa powstałej statystyki pochodzi od nazwiska jej twórcy, brytyjskiego hydrologa Harolda Edwina Hursta, który w trakcie swej pracy przy projektowaniu i budowie zbiorników na Nilu odkrył i opisał nową metodę statystyczną. Narzędzie to pozwala analizować szeregi czasowe jak również rozróżnić ich charakter poprzez wartość wykładnika Hursta. Można wyróżnić trzy grupy procesów w zależności od jego wartości:

1. $H = 0.5$ – szereg losowy, brak korelacji,
2. $0 < H < 0.5$ – szereg antypersystentny,
3. $0.5 < H < 1$ – szereg persystentny.

W przypadku szeregu antypersystentnego proces pokonuje mniejszą drogę niż błądzenie losowe. Dlatego ma też tendencję do ciągłego „zawracania”. Gdy jest wzrastający, to zaczyna szybko maleć i odwrotnie, po spadku następuje szybki wzrost. Szeregi zaliczane do persystentnych pokonują większy dystans niż błądzenie losowe. Gdy proces ma tendencję wzrostową, to z dużym prawdopodobieństwem tą tendencję utrzyma i podobnie w przypadku spadku.

Powstała teoria została później poprzez pracę [4] rozszerzona o procesy związane z gospodarką i rynkami kapitałowymi. Do dnia dzisiejszego powstało wiele metod wyznaczania wykładnika Hursta. Są one wykorzystywane w wielu dziedzinach nauki. Zwrócono szczególną uwagę na zastosowanie statystyki Hursta do analizy i przewidywania zachowania się kursów spółek giełdowych na rynkach kapitałowych [11]. Badając szeregi czasowe farm wiatrowych postanowiono zaadaptować jeden z algorytmów [11] do wyznaczenia wykładników Hursta.

Dla szeregu czasowego

$$(6) \quad X = X_1, X_2, \dots, X_n$$

Oblicza się wartość średnią

$$(7) \quad m = \frac{1}{n} \sum_{i=1}^n X_i$$

Dokonyje centrowania szeregu

$$(8) \quad Y_t = X_t - m, \quad t = 1, 2, \dots, n$$

Wylicza skumulowane szeregi czasowe

$$(9) \quad Z_t = \sum_{i=1}^t Y_i, \quad t = 1, 2, \dots, n$$

Oblicza rozstępy skumulowanych szeregów czasowych

$$(10) \quad R_t = \max(Z_1, Z_2, \dots, Z_t) - \min(Z_1, Z_2, \dots, Z_t), \quad t = 1, 2, \dots, n$$

Wyznacza odchylenie standardowe

$$(11) \quad S_t = \sqrt{\frac{1}{t} \sum_{i=1}^t (X_i - u)^2}, \quad t = 1, 2, \dots, n$$

gdzie: u to wartość średnia szeregu liczona od X_1 do X_t

Oblicza średni przeskalowany zasięg

$$(12) \quad \left(\frac{R}{S}\right)_t = \frac{R_t}{S_t}, \quad t = 1, 2, \dots, n$$

podzbiorów

$$(13) \quad [X_1, X_t], [X_{t+1}, X_{2t}], \dots, [X_{(m-1)t+1}, X_{mt}]$$

gdzie: m jest zaokrągleniem w dół do liczby całkowitej

ilorazu $\frac{n}{t}$.

Hurst sformułował zależność:

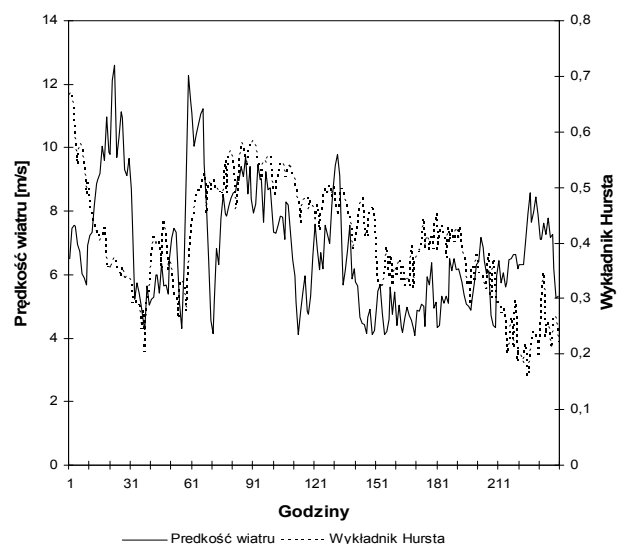
$$(14) \quad \left(\frac{R}{S}\right)_t = ct^H$$

gdzie: c – stała, H – wykładnik Hursta

Dokonyjąc logarytmowania równania (14) otrzymuje się zależność:

$$(14) \quad \log\left(\frac{R}{S}\right)_t = \log c + H \log t$$

Stosując regresję liniową metodą najmniejszych kwadratów oblicza się nachylenie wykresu logarytmów przeskalowanego zasięgu w stosunku do osi logarytmów czasu, co odpowiada wartości wykładnika Hursta.




Rys.2. Prędkość wiatru zanotowana dla farmy wiatrowej oraz wyznaczone wykładniki Hursta

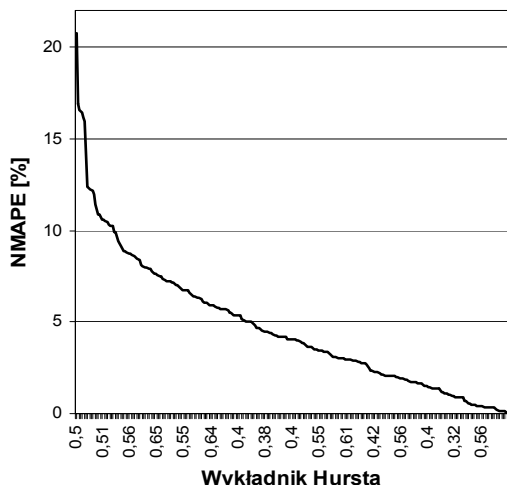
Wyniki przeprowadzonego eksperymentu

Do przeprowadzenia eksperymentalnych badań wybrano farmę wiatrową o łącznej mocy zainstalowanej 90 MW. Zbudowano dwa modele eksperymentalne. W pierwszym przypadku Model MRK-R zawierał jedną

zmienną objaśniającą (wejściową), którą była prognozowana dla danej godziny doba prędkość wiatru. W drugim przypadku model MRK-H wzbogacono o dwie dodatkowe zmienne objaśniające, którymi były wyznaczone z przebiegów prędkości wiatru oraz z przebiegu mocy generowanej w farmie współczynniki Hursta opóźnione o 24 godziny.



Rys.3. Moc generowana na farmie wiatrowej oraz wyznaczone wykładniki Hursta



Rys.4. Zmiana wykładnika Hursta wyznaczonego dla mocy farmy wiatrowej w funkcji błędu NMAPE.

Chcąc uzyskać miarodajne porównanie przedstawionych metod prognostycznych każdy z modeli był uczony na tej samej próbie danych, a weryfikacja wyników następowała również w oparciu o zestaw informacji identyczny dla każdego modelu. Wybrano losowo odcinek pracy farmy wiatrowej składający się z 1300 godzin obserwacji. Do wyznaczenia parametrów modeli użyto 960 obserwacji (60 obserwacji należało pominąć ze względu na sposób wyznaczania wykładników Hursta dla których dobrano taki interwał wylczeniowy). Wykonano sprawdzające prognozy krokowe na 240 godzin do przodu z interwałem krokowym 30 godzin.

Wielu autorów poszukując skutecznych metod oceny i porównania metod prognostycznych dotyczących prognoz dla farm wiatrowych wprowadza tzw. normalizację błędów. Wielkością do której przyrównywana jest wartość błędów prognozowanej mocy elektrowni wiatrowej jest jej wartość nominalna wprowadza się tzw. znormalizowany średni bezwzględny błąd procentowy NMAPE (ang. Normalized Mean Absolute Percentage Error)

Tabela 1. Średnie, maksymalne i minimalne znormalizowane bezwzględne błędy procentowe uzyskane w eksperymencie dla badanych metod predykcji

	NMAPE			
	N	Min	Max	Śre
Model	[-]	[%]	[%]	[%]
MRK-R	240	0,01	21,9	5,3
MRK-H	240	0,03	20,7	4,7

Analizując wyznaczone wykładniki Hursta potwierdza się, że w zależności od charakteru przebiegu czasowego, dla którego został on wyznaczony niesie on w sobie dodatkową informację o procesie, którą można efektywnie wykorzystać w modelach.

Podsumowanie

Wyniki tak nieskomplikowanie zdefiniowanego eksperymentu zostały ocenione jako bardzo obiecujące i w pełni uzasadniają kontynuację badań. W dalszych badaniach należałoby zastanowić się nad poszukiwaniem optymalnego zbioru danych wejściowych do modelu MRK, odpowiednim doбором okresu nauki modelu oraz samych parametrów związanych z rozkładem kanonicznym. Na skutek takich działań spodziewane jest polepszenie wyników prognoz.

LITERATURA

- [1] Cieślak M, i inni.; Prognozowanie gospodarcze. Metody i zastosowanie, *Wydawnictwo Naukowe PWN*, Warszawa 2001
- [2] Dobrzańska I., Dąsał K., Łyp J., Popławski T., Sowiński J.: Prognozowanie w elektroenergetyce. Zagadnienia wybrane. *Wydawnictwo P Cz.*, Częstochowa 2002
- [3] Dudek G.: Analiza modelu krótkoterminowego prognozowania obciążeń systemów elektroenergetycznych opartego na klasteryzacji rozmytej. *Badania Operacyjne i Decyzje*, nr 2, str. 15-34, 2007
- [4] Peters E. E., *Chaos And Order In The Capital Markets - A New View Of Cycles, Prices, And Market Volatility*, Second Edition, New York, *John Wiley & Sons*, (1996).
- [5] Popławski T.: Methods of analysis and forecast of power engineering load variation in the conditions of energy market transformation. *Wydawnictwo Politechniki Częstochowskiej*, (2009)
- [6] Popławski T. (redaktor): Wybrane zagadnienia prognozowania długoterminowego w systemach elektroenergetycznych. *Wydawnictwo Politechniki Częstochowskiej*, (2012)
- [7] Popławski T., Dąsał K., Medvec Z.: The New Aspects using MRK Model for Short-Term Load Forecasting in the Power System. *Energy Spectrum*, Vol. 4 nr 2:68-72, 2009.
- [8] Popławski T., Szeląg P., Analiza fraktalna w prognozowaniu procesów samopodobnych, *Śląskie Wiadomości Elektryczne*, Vol. 17, No. 5, 2010, 30-33.
- [9] Sowiński J.: Forecasting models of prices in analysis of power system investments under uncertainty, *Polityka Energetyczna*, IGSMiE PAN, Tom 6, 2003, PL ISSN 1429-6675, p. 85-94
- [10] Stewart I., Czy Bóg gra w kości? *Nowa matematyka chaosu*, Warszawa, PWN, 2001.
- [11] Qian B., Rasheed K., Hurst exponent and financial market predictability, from Proceeding: *Financial Engineering and Applications*, Cambridge, USA, 8-10 November 2004
- [12] World Wind Energy Report 2009, 2010, 2011, 2012

Autor: Dr hab. inż. Tomasz Popławski Prof. PCz. Politechnika Częstochowska, Instytut Elektroenergetyki, ul. Armii Krajowej 17, 42-200 Częstochowa, E-mail: poptom@el.pcz.czest.pl