

doi:10.15199/48.2015.12.69

Krótkoterminowe prognozy cen na Towarowej Giełdzie Energii z wykorzystaniem modelu trendu pełzającego

Streszczenie. Artykuł porusza problematykę prognozowania krótkoterminowej ceny energii elektrycznej na rynku energii. Badania przeprowadzone zostały na rzeczywistych danych z Rynku Dnia Następnego (RDN). Zaproponowano kilka modeli prognostycznych, szczególnie model trendu pełzającego dla przewidywania cen w horyzoncie dobowym. Wykonane zostały prognozy wygaste wraz z oceną dokładności oraz prognozy walidacyjne umożliwiające ocenę użyteczności zaprezentowanych modeli.

Abstract. Article raises the problem of short-term forecasting the electricity price on the energy market. Research were conducted on real data from the Day-Ahead Market. Proposed several forecasting models, especially creeping trend model to predict prices in the weekly horizon. Taken extinct forecasts with evaluation of the accuracy and forecast validation for the assessment of usefulness of models presented. (Short-term forecasting prices on Polish Power Exchange using creeping trend model).

Słowa kluczowe: Rynek energii, cena, prognozowanie krótkoterminowe, trend pełzający.

Keywords: Energy market, price, short-term forecasting, creeping trend.

WPROWADZENIE

System elektroenergetyczny ze względu na swoją specyfikę wymaga uzyskania dokładnych prognoz. Szczególnie ważne są prognozy w krótkim horyzoncie czasowym [1]. Metod prognostycznych jest wiele. W zależności od celu oraz przedmiotu badania można wybrać proste lub bardziej złożone techniki prognozowania [1], [2], [3], [4], [5], [6] [7], [8]. Coraz częściej wykorzystuje się metody sztucznej inteligencji do prognozowania w elektroenergetyce. Świadczą o tym publikacje [8], [9]. Pojawiają się także opracowania metod i modeli do przewidywania produkcji energii ze źródeł odnawialnych [10], [11]. Prognozowanie cen na Towarowej Giełdzie Energii jest zagadnieniem nowym, w związku z czym w literaturze nie ma zbyt wielu metod dotyczących przewidywania tego procesu. Pojawiają się natomiast publikacje, nawiązujące do tego problemu [12], [13], [14], [15], [16].

Autorzy w artykule pragną przedstawić kilka prostych w budowie metod, które w ich mniemaniu dobrze opisują dane zjawisko. Szczególną uwagę zwrócono na model trendu pełzającego z wagami harmonicznymi, który jest modelem adaptacyjnym. Model ten w klasycznej wersji stosuje regresję liniową do wyznaczania tendencji rozwojowej. W wyniku badań został opracowany autorski program wykorzystujący model trendu pełzającego do prognozowania różnych zjawisk. Jest to wersja testowa programu, w fazie dalszej rozbudowy. Zakłada się zastosowanie innych wybranych metod wyznaczania tendencji rozwojowej np. nieliniowych (logarytmiczna, potęgowa, czy wielomian stopnia n itp). Z czasem program zostanie rozbudowany o inne metody prognozowania, jak np. metodę analizy Fouriera.

Analiza statystyczna danych źródłowych


Dane zostały zaczerpnięte z oficjalnej strony TGE: www.polpx.pl. Dotyczą one cen energii notowanych na Rynku Dnia Następnego (RDN) obejmujących okres trzech miesięcy, tj. kwietnia, maja i czerwca 2012 roku w systemie godzinowym. Skonstruowany na podstawie danych szereg czasowy poddano wstępnej analizie statystycznej.

Pierwotnie szereg obejmuje wszystkie 91 dni, a więc dni robocze i świąteczne. Szereg ten został jednak zmodyfikowany, usunięto z niego soboty, niedziele i święta, następnie poddano go ponownej analizie.


Zostało przeprowadzonych kilka testów, między innymi na stacjonarność i normalność rozkładu. Wykonano analizę

spektralną w celu wykrycia okresowości oraz analizę autokorelacji ACF i autokorelacji cząstkowej PACF.

Wykres badanego szeregu czasowego przedstawia rysunek 1, natomiast rysunek 2 prezentuje szereg po modyfikacji.



Rys.1. Fragment przebiegu badanego szeregu czasowego cen energii (obejmujący okres 91 dni)



Rys.2. Fragment przebiegu badanego szeregu czasowego cen energii po modyfikacji (obejmującego 61 dni)

Wyniki testów i analiz przed oraz po modyfikacji nie uległy zmianie. W dalszej części będą prezentowane jednak analizy zmodyfikowanego szeregu. Na podstawie rysunku 1, 2 oraz obliczonych statystyk liczbowych stwierdzono, że

cen energii na RDN charakteryzują się dużym odchyleniem standardowym i wariancją. W związku z czym ich przebiegi są bardzo zróżnicowane.

W celu zbadania stacjonarności przeprowadzone zostały testy ADF (rozszerzony test Dickey-Fullera) i KPSS (test Kwiatkowskiego, Phillipsa, Schmidta i Shina). Hipoteza zerowa w teście ADF zakłada niestacjonarność, podczas gdy w teście KPSS zakłada stacjonarność badanego procesu [17], [18]. Do wykonania i przeprowadzenia testów użyto programu Gretl¹. Wyniki przedstawia tabela 1.

Tabela 1. Wyniki testu stacjonarności cen energii

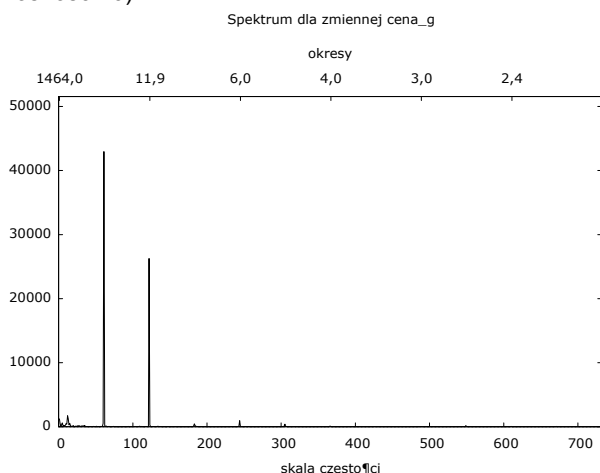
Test na stacjonarność		
ADF		KPSS
stat. testu	wartość p	stat. testu
-5,37*	3,124e-005	0,09*
* - stacjonarność		

Obydwa testy wykazują stacjonarność cen energii na RDN. Kolejnym przeprowadzonym testem jest test na normalność rozkładu (tabela 2).

Tabela 2 Wyniki testu normalności dla cen energii notowanych

Test na normalność		
Shapiro-Wilka	wartość	0,943502
	p-value	3,19307e-023
Jarque'a-Bera	wartość	119,486
	p-value	1,13205e-026
* - normalność rozkładu		

Hipoteza zerowa zarówno testu Jorge-Bera jak i Shapiro-Wilka zakłada normalność rozkładu. Z tabeli 2 odczytujemy, że ceny nie mają rozkładu normalnego. Będzie to rozkład spłaszczony o asymetrii lewostronnej (na podstawie wyliczonych statystyk opisowych kurtoza <3 i skośność <0).



Rys.3. Wykres analizy spektralnej – periodogram dla cen energii

W celu określenia sezonowości została przeprowadzona analiza spektralna. Analiza spektralna jest modyfikacją analizy Fouriera [1], [17]. Przykładowy periodogram przedstawia rysunek 3.

Wartość periodogramu interpretowana jest jako wariancja, której odpowiadają wahania o konkretnej

¹ Gretl (Regression Econometric and Time_Series Library) należy do grupy oprogramowania Open Source, czyli Powszechnej Licencji Publicznej GNU (GNU General Public License). Autorem oprogramowania jest Allin Cottrell z Uniwersytetu Wake Forest w Północnej Karolinie w USA.

częstotliwości lub okresie. Wykryte zostały dwie najsilniejsze okresowości w badanym szeregu odpowiadające: 24 i 12 godzinom.

Wykonana została także analiza autokorelacji ACF i autokorelacji cząstkowej PACF. Funkcja autokorelacji ACF bada zależność między obserwacjami oddległymi w czasie. Podaje zależność między wartościami współczynnika autokorelacji, a rzędem opóźnień.

Funkcja autokorelacji cząstkowej PACF określa związek (korelację) pomiędzy obserwacjami oddalonymi od siebie o k opóźnień. Analizy te służą do zdefiniowania odpowiedniego modelu ARMA/ARIMA [3], [5], [17].

Metody prognostyczne

Wykonane analizy i testy upoważniają do zastosowania kilku modeli, które są przydatne do krótkoterminowych prognoz. Jak wcześniej wspomniano wybrano proste modele jak: wygładzanie Holt'a, Winters'a oraz model trendu pelzającego. Dwie pierwsze metody są powszechnie znane stąd ich opis zostanie pominięty. Szczegółowo zostały omówione w literaturze [19], [20].

Algorytm budowy modelu trendu pelzającego i prognozowania jest następujący:

Dostępne są obserwacje: $y_1, y_2, y_3, \dots, y_n$

Krok 1: Ustalenie arbitralnie wartości stałej wygładzania $k < n$

Krok 2: Podział na $(n - k + 1)$ grup, i szacowanie na podstawie kolejnych fragmentów szeregu o długości k ,

$$y_1, \dots, y_k \quad \dots \quad y_{n-k+1}, \dots, y_n$$

funkcji trendu:

$$(1) \quad f_1(t) = \alpha_1 + \beta_1 t \quad \text{dla } 1 \leq t \leq k,$$

$$f_{n-k+1}(t) = \alpha_{n-k+1} + \beta_{n-k+1} t \\ \text{dla } n - k + 1 \leq t \leq n$$

Krok 3: Obliczenie wygładzonych wartości zmiennej $f_j(t)$, z j-tej funkcji trendu.

$$(2) \quad f_j(t) = \alpha_j + \beta_j t$$

Krok 4: Obliczenie średniej wartości wygładzonej \bar{y}_t dla każdego okresu t jako średniej arytmetycznej wartości wygładzonych obliczonych dla tego okresu w kroku 3. Dla dowolnego $t(1 \leq t \leq n)$ wartościom y_t odpowiadają wygładzone wartości teoretyczne otrzymane za pomocą niektórych spośród podanych funkcji $f_1(t) = \alpha_1 + \beta_1 t (j = 1, \dots, n - k + 1)$. Są to funkcje, dla których: $d(t) \leq j \leq g(t)$.

Połączenie odcinkami liniowymi kolejnych punktów (t, \bar{y}_t) generuje wykres wygładzonych wartości szeregu czasowego w postaci funkcji segmentowej, zwanej trendem pelzającym. Ostateczne wygładzenie dla $j = d(t), \dots, g(t)$:

$$(3) \quad \bar{y}_t = \frac{1}{1 + g(t) - d(t)} \sum_{j=d(t)}^{g(t)} f_j(t)$$

gdzie:

$$(4) \quad d(t) = \begin{cases} 1 & \text{dla } t = 1, 2, \dots, k \\ t - k + 1 & \text{dla } t = k + 1, \dots, n \end{cases}$$

$$g(t) = \begin{cases} 1 & \text{dla } t = 1, 2, \dots, n - k + 1 \\ n - k + 1 & \text{dla } t = n - k + 2, \dots, n \end{cases}$$

Krok 5: Ekstrapolacja modelu trendu pelzającego. Obliczenie przyrządów funkcji trendu (5) dla wygładzonych wartości procesu:

$$(5) \quad w_{t+1} = \bar{y}_{t+1} - \bar{y}_t, \quad t = 1, \dots, n-1$$

Szczegółowiej procedury opisano w [1, 9]. Wzór końcowy służący do wyznaczenia prognozy jest następujący:

$$(6) \quad \hat{y}_T = \bar{y}_{t=n} + (T-n) \cdot \bar{w},$$

\bar{w} - jest średnim przyrostem trendu wyznaczonym jako średnia ważona wagami harmonicznymi.

Wyniki eksperymentu

Wybrane modele zostały ocenione pod względem dokładności dopasowania. Prognoza została wykonana krokowo godzina po godzinie na 5 kolejnych dni. Wyniki przedstawia tabela 3.


Tabela 3. Błędy dopasowania modeli dla cen energii na RDN

		Błąd średni MAPE [%]
Winters	Addytywny	10,33
	Multiplikatywny	5,89
Holt	Model 1	5,10
	Model 2	4,93
Trend pelzający	k = 3	4,74
	k = 4	4,61
	k = 5	4,53
	k = 6	4,5

Najlepsze rezultaty osiągnął model trendu pelzającego. Przetestowany został wpływ parametru wygładzania k (od wartości 3 do 6) na dokładność modelowania. Dla k=6 średni błąd MAPE dopasowania był najmniejszy i osiągnął 4,50%. Niewiele gorszy był dla k=5. Wyniki wszystkich uzyskanych prognoz przedstawiono w tabeli 4.

Tabela 4. Średnie błędy MAPE wyznaczonej prognozy dla cen energii na RDN

		Błąd średni MAPE [%]
Winters	Addytywny	4,51
	Multiplikatywny	7,01
Holt	Model 1	2,98
	Model 2	3,17
Trend pelzający	k = 3	3,07
	k = 4	2,69
	k = 5	2,4
	k = 6	2,14




Rys.4. Błąd MAPE dla cen energii na RDN

Najmniejsze błędy prognozy uzyskano dla modelu trendu pelzającego. Zasadne jest więc stosowanie tego modelu w prognozowaniu cen energii na RDN. Najmniejszy błąd 2,14% osiągnięto dla parametru k=6. Parametry te były przyjmowane subiektywnie. Im większa jego wartość tym prognoza jest bardziej dokładna, a przebiegi bardziej dopasowane do rzeczywistych danych.

Na rysunku 4 przedstawiono rosnąco wykres błędów dla wybranych metod prognostycznych. Porównano model Holta 1 i 2, Winters'a addytywny i multiplikatywny oraz trend pelzający (k=6). Model trendu pelzającego wskazany jest jako najlepszy (dający najmniejsze błędy prognoz). Nieco gorsze są modele Holta, różniące się między sobą założeniami początkowymi. Największe błędy uzyskano modelem Winters'a w postaci addytywnej.

Fragment przebiegu rzeczywistego (Y) i prognozowanego (Yt) dla modelu trendu pelzającego o stałej wygładzania k=6 ilustruje rysunek 5 poniżej.



Rys.5. Fragment przebiegu rzeczywistego (Y) i prognozowanego (Yt) dla cen energii notowanych na Rynku Dnia Następnego

Podsumowanie

Z przeprowadzonej analizy wynika, że ceny energii notowane na Rynku Dnia Następnego mają duże zróżnicowanie, co sprawia że ich prognozowanie jest trudnym zadaniem. W literaturze ciężko odszukać metod nawiązujących do tego problemu. Autorzy chcieli poruszyć tę tematykę i podzielić się własnymi wynikami przeprowadzanych doświadczeń. Z badań wynika, że rozkłady cen nie są rozkładami normalnymi, wykazują natomiast stacjonarność swoich procesów. Wykryto w nich okresowości odpowiadające 24 i 12 godzinom.

Wykonano symulacje wykorzystując różne metody. Najlepsze dokładności osiągnął model trendu pelzającego. W zależności od zwiększania parametru wygładzania k błędy malały. W wykonanej prognozie (przy stałej k=6) błędy były na poziomie nieco ponad 2%. Prognozę uważa się za poprawną.

Autorzy w artykule udowodnili zasadność stosowania metody trendu pelzającego do prognozowania cen na Towarowej Gieldzie Energii. Model może być stosowany także do predykcji innych procesów systemu elektroenergetycznego.

Na podstawie wykonanego testu na stacjonarność oraz analizy autokorelacji ACF i autokorelacji cząstkowej PACF do prognozowania cen można próbować zastosować także modele klasy ARMA/ARIMA. Wykonane analizy są pomocne w celu zdefiniowania odpowiednich parametrów wymienionych modeli. Autorzy zostawiają zatem otwartą ścieżkę co do zastosowania modeli klasy ARMA/ARIMA w prognozowaniu cen na TGE.

LITERATURA

1. Cieślak M., i inni.: Prognozowanie gospodarcze. Metody i zastosowanie, Wydawnictwo Naukowe PWN, Warszawa 2001
2. Dąsał K., Popławski T.: Problemy związane z prognozowaniem zużycia energii elektrycznej w Polsce. *Polityka energetyczna*, (2008), Tom 11 Zeszyt 1, 101-116
3. Dobrzańska I., Dąsał K., Łyp J., Popławski T., Sowiński J.: Prognozowanie w elektroenergetyce. Zagadnienia wybrane. Wydawnictwo Politechniki Częstochowskiej, Częstochowa 2002
4. Dittmann P.: Prognozowanie w przedsiębiorstwie. Metody i ich zastosowanie. Oficyna ekonomiczna, Kraków 2004
5. Dudek G.; *Modele ARIMA do krótkoterminowego prognozowania obciążeń systemów elektroenergetycznych*. Rynek Energii (2012),2 (99), 94-98
6. Dudek G.; *Modele wygładzania wykładniczego do krótkoterminowego prognozowania obciążeń systemów elektroenergetycznych*. Rynek Energii (2013), nr I (VIII), 64-69
7. Halicka K., Wieńkowski C.: Wykorzystanie metod wygładzania wykładniczego do prognozowania kursu sprzedaży EUR. *Ekonomia i Zarządzanie*, Oficyna Wydawnicza Politechniki Białostockiej, (2013), Białystok. T. 5, nr 2
8. Piotrowski P., Prognozowanie w elektroenergetyce w różnych horyzontach czasowych, Monografia, Prace Naukowe Politechniki Warszawskiej „Elektryka”, (2013), z. 144, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa
9. Dudek G.; Prognozowanie krótkoterminowe obciążeń systemów elektroenergetycznych z wykorzystaniem rozmytych drzew regresyjnych. *Przegląd Elektrotechniczny* (2014), R.90, nr 4, 108-111,.
10. Piotrowski P.: Analiza statystyczna danych do prognozowania ultrakrótkoterminowego produkcji energii elektrycznej w systemach fotowoltaicznych, *Przegląd Elektrotechniczny*, (2014), nr.4/ R.90, 1-4
11. Piotrowski P., Baczyński D.: Prognozowanie dobowej produkcji energii elektrycznej przez turbinę wiatrową z horyzontem 1 doby, *Przegląd Elektrotechniczny* (2014), nr.9/ R.90, 113-117
12. Popławski T., Łyp J., Kurach M.: Wykorzystanie modelu rozkładu kanonicznego wektora zmiennych losowych do prognozy cen na rynku dnia następnego. *Rynek Energii*, (2012) nr 1(98), 54-58
13. Ejdyś J., Halicka K., Godlewska J.; Prognozowanie cen energii elektrycznej na giełdzie energii. *Zeszyty Naukowe. Organizacja i Zarządzanie*, Politechnika Śląska, (2015), 53-61
14. Góra A., Strzała K., ; Prognozowanie ceny energii na TGE SA : analiza empiryczna, *Zarządzanie i Finanse* (2013), R. 11, nr 3, cz. 2, 17-32
15. Weron R. *Electricity price forecasting: A review of the state-of-the-art with a look into the future*, *International Journal of Forecasting* (2014) 30(4), 1030-1081
16. Weron R., Zator M. *Revisiting the relationship between spot and futures prices in the Nord Pool electricity market*, *Energy Economics* (2014) 44, 178-190
17. Kufel T.: *Ekonometria. Rozwiązywanie problemów z wykorzystaniem programu Gretl*. Wydawnictwo Naukowe PWN, Warszawa 2007
18. Lipiec-Zajchowska M., [red]; *Optymalizacja procesów decyzyjnych*. Wydawnictwo Naukowe Wydziału Zarządzania Uniwersytetu Warszawskiego, Warszawa 1999
19. Dąsał K., Popławski T.: Model trendu pelzającego w prognozowaniu zużycia energii elektrycznej małych odbiorców. *Rynek Energii*, (2009) Nr II(IV), 324-329
20. Dąsał K., Popławski T., Kurach M., Rusek K., *Analiza i prognoza cen wybranych paliw biomasowych na krajowym rynku energii i UE. Materiały pokonferencyjne ZET* (2011), 23-39

Autorzy:

dr hab. inż. Tomasz Popławski prof. PCz., Politechnika Częstochowska, Instytut Elektroenergetyki, Zakład Wytwarzania, Urządzeń i Gospodarki Elektroenergetycznej, Al. Armii Krajowej 17, 42-200 Częstochowa, E-mail: poptom@el.pcz.czest.pl;

mgr inż. Monika Weźgowiec, Politechnika Częstochowska, Instytut Elektroenergetyki, Zakład Wytwarzania, Urządzeń i Gospodarki Elektroenergetycznej, Al. Armii Krajowej 17, 42-200 Częstochowa, E-mail: m.wezgowiec@el.pcz.czest.pl;