

MODELE ARIMA DO KRÓTKOTERMINOWEGO PROGNOZOWANIA OBCIĄŻEŃ SYSTEMÓW ELEKTROENERGETYCZNYCH

Grzegorz Dudek

Słowa kluczowe: krótkoterminowe prognozowanie zapotrzebowania na moc elektryczną, ARIMA

Streszczenie. Przedstawiono jednowymiarowe modele autoregresji i średniej ruchomej do sporządzania krótkoterminowych prognoz zapotrzebowania na moc. Szeregi czasowe obciążeń wykazują trend oraz trzy okresy wahań sezonowych: roczny, tygodniowy i dobowy, co komplikuje budowę modelu prognostycznego. W celu uproszczenia zadania szereg czasowych poddano dekompozycji stosując dwa podejścia. Pierwsze polega na wydzieleniu odrębnych szeregów dla każdej godziny doby. Drugie podejście wykorzystuje regresję lokalną (LOESS) do dekompozycji szeregu na trend, składową sezonową i błąd. Niestacjonarny charakter szeregów zdekomponowanych wymusza zastosowania zintegrowanego modelu ARMA. Dokładność proponowanych metod porównano na przykładach aplikacyjnych z dokładnością modelu opartego na sieci neuronowej.

1. WSTĘP

Znaczenie prognozowania obciążeń w bieżącej eksploatacji systemu elektroenergetycznego i funkcjonowaniu rynków energii przekłada się na ogromną liczbę publikacji opisujących modele prognostyczne dedykowane temu problemowi. Obok klasycznych rozwiązań wykorzystujących metody analizy statystycznej, regresji i wygładzania pojawiają się modele oparte na intensywnie ostatnio rozwijanych metodach inteligencji obliczeniowej, uczenia maszynowego czy rozpoznawania obrazów. Historyczny obraz konwencjonalnych metod krótkoterminowego prognozowania obciążeń elektroenergetycznych (KPOE) daje przeglądowy artykuł Grossa i Galiany z 1987 roku [6]. Autorzy wyodrębniają dwie klasy modeli KPOE. Pierwsza klasa (*time-of-day models*) obejmuje modele w których prognozowane obciążenie jest kombinacją liniową skończonej liczby funkcji czasu $f_i(t)$ i białego szumu $\xi(t)$:

$$P(t) = \sum_{i=1}^n \alpha_i f_i(t) + \xi(t), \quad t \in T, \quad (1)$$

gdzie T jest okresem prognozy (np. 24 h).

Funkcje $f_i(t)$ są najczęściej sinusoidalne. Parametry modelu (wagi poszczególnych funkcji) można oszacować poprzez regresję liniową w oparciu o dane historyczne. Zaletą tych modeli jest czytelna struktura i prosty sposób aktualizacji parametrów. Wśród wad wymienia się ograniczoną dokładność w odwzorowaniu stochastycznej natury procesu oraz ignorowanie dodatkowych zmiennych objaśniających, np. pogodowych.

W drugiej klasie modeli (*dynamic models*) obok

funkcji czasu wprowadza się zmienne objaśniające związane z zachowaniem przebiegu czasowego obciążeń w przeszłości, czynników pogodowych i losowych. Popularnym reprezentantem tej klasy są modele autoregresyjne, których ogólna postać zawiera dwa składniki. Pierwszy składnik wyraża udział w obciążeniu czynników zależnych od czasu w „normalnych” warunkach pogodowych dla określonego dnia prognozy. Komponent ten może być reprezentowany przez sumę funkcji periodycznych (1). Drugi składnik jest addytywnym wyrażeniem resztowym opisującym odchylenia od spodziewanego przebiegu obciążenia spowodowane odchyleniami warunków pogodowych od „normalnych” oraz czynnikami losowymi. Komponent resztowy można zamodelować procesem autoregresji i średniej ruchomej postaci [6]:

$$y(t) = \sum_{i=1}^p a_i y(t-i) + \sum_{j=1}^J \sum_{k=1}^r b_k u_j(t-k) + \sum_{l=1}^q c_l \xi(t-l), \quad (2)$$

gdzie: a_i, b_k, c_l, p, q i r są parametrami modelu, $u_j(t)$, $j = 1, 2, \dots, J$ reprezentuje wejścia zależne od czynników pogodowych (funkcje odchylen zmiennych pogodowych: temperatury atmosferycznej, wilgotności, nasłonecznienia, opadów, od ich wartości normalnych w chwili t), a $\xi(t)$ jest procesem losowym o zerowej średniej, który pozwala uwzględnić stochastyczny charakter przebiegu obciążeń.

Parametry a_i, b_k, c_l oraz p, q i r (parametry rzędu) identyfikowane są przez dopasowanie modelu do danych historycznych. Rzędy modelu dobiera się analizując funkcje autokorelacji i autokorelacji cząstkowej.

Ponieważ szeregi czasowe obciążeń z reguły są niestacjonarne, aby zastosować model autoregresji i średniej ruchomej bezpośrednio do modelowania tych szeregów przekształca się je na stacjonarne poprzez różnicowanie (szeregi zintegrowane).

Autoregresyjne modele z powodzeniem stosowane są w KPOE do dzisiaj, często w połączeniu z innymi metodami. Np. w [5] zastosowano periodyczny model autoregresyjny (PAR) rozbijając równanie autoregresji na indywidualne równania dla każdej godziny doby i wprowadzając zmienne egzogeniczne reprezentujące dzień tygodnia, miesiąc kalendarzowy i temperatury atmosferyczne. Dekompozycję modelu autoregresyjnego na poszczególne godziny doby zastosowano także w [12]. Model prognostyczny stanowi tutaj kombinację funkcji sinusoidalnych i reszt modelowanych procesem autoregresyjnym. Dwustopniową procedurę prognostyczną zaproponowano w [10]. W pierwszym kroku usuwa się sezonowość i trend używając metody średniej ruchomej. Otrzymany w wyniku komponent stochastyczny będący realizacją procesu stacjonarnego modeluje się za pomocą metody ARMA. Złożenie prognozy komponentu stochastycznego z trendem i komponentem sezonowym daje prognozę obciążenia. W [2] opisano autoregresyjny model z gładkim przejściem (*smooth transition periodic autoregressive – STPAR*), gdzie sezonowość wyrażają wagi stojące przy zmiennych opóźnionych. Wagi wyznacza się z sumy funkcji sinusoidalnych o okresach odpowiadających okresowi dobowemu i tygodniowemu. Dodatkowy składnik modelu, wyrażony za pomocą funkcji logistycznej, pozwala uwzględnić nieliniowy wpływ zmiennych egzogenicznych. W [1] do estymacji parametrow modelu autoregresyjnego ze zmiennymi pogodowymi (temperaturą i prędkością wiatru), który konstruowano dla każdej prognozowanej wartości obciążenia godzinowego, użyto filtru Kalmana. W [14] zaproponowano samorganizujący się rozmyty model ARMAX, gdzie do doboru zmiennych wejściowych, optymalnego podziału przestrzeni rozmytych i doboru funkcji przynależności użyto programowania ewolucyjnego. Hybrydową metodę optymalizacji opartą na algorytmach ewolucyjnych i algorytmie roju cząstek do identyfikacji parametrów modelu ARMAX w zadaniu KPOE opisano w [7]. W [9] połączono model ARIMA z transformacją falkową. W podejściu tym oryginalny szereg czasowy dekomponuje się na kilka szeregów składowych o różnej rozdzielczości przy pomocy schematu liftingu (*lifting scheme*). Schemat liftingu pozwala wydobyć interesujące charakterystyki oryginalnego szeregu (elementy strukturalne). Problemy konstrukcji modeli

autoregresji i średniej ruchomej w kontekście prognozowania obciążeń elektroenergetycznych omówiono szczegółowo w monografii [13].

W tym artykule opisano jednowymiarowe modele ARIMA działające na zdekomponowanych szeregach czasowych obciążeń systemów elektroenergetycznych. W jednowymiarowych modelach szeregów czasowych o przebiegu zmiennej wnioskuje się jedynie na podstawie historycznych obserwacji tej zmiennej. Budowa takich modeli jest uzasadniona, gdy istnieją powiązania pomiędzy obserwacjami zmiennej prognozowanej w różnych okresach. Zaprezentowano dwa sposoby dekompozycji szeregów czasowych. Pierwszy polega na rozbiciu szereg czasowego na odrębne szeregi dla każdej godziny doby, a drugi wykorzystuje regresję lokalną do dekompozycji szeregu na trend, składową sezonową i błąd.

2. MODELE ARIMA

Do prognozowania szeregów czasowych obciążeń, które wykazują niestacjonarność i wielosezonowość, używa się zintegrowanych sezonowych modeli autoregresji i średniej ruchomej. W modelach do prognoz krótkoterminowych zwykle nie uwzględnia się sezonowości rocznej, wykorzystując do estymacji modelu fragment szeregu czasowego o znacznie mniejszej długości niż okres roczny. Rzadko także spotyka się modele z podwójną sezonowością – tygodniową i dobową, z uwagi na kombinatoryczny problem doboru rzędów modelu, który przybiera znaczne rozmiary dla modeli z wieloma cyklami sezonowymi. Częściej szereg czasowy obciążeń dekomponuje się i komponenty, wykazujące mniejszą złożoność niż szereg oryginalny, prognozuje się niezależnie. Takie podejście zastosowano np. w [10], gdzie szereg zdekomponowano na składową sezonową, trend i składową stochastyczną, w [9], gdzie do dekompozycji na szeregi o różnej rozdzielczości wykorzystano transformację falkową i w [12], gdzie zdefiniowano odrębne szeregi czasowe dla każdej godziny doby. Ten ostatni sposób dekompozycji zastosowano również tutaj.

Definiuje się 24 szeregi czasowe obciążeń systemu w tej samej godzinie doby. Dzięki temu zabiegowi eliminuje się sezonowość dobową. Do niezależnego modelowania tych szeregów wykorzystuje się zintegrowany sezonowy model autoregresji i średniej ruchomej $ARIMA(p, d, q) \times (P, D, Q)_m$:

$$\Phi(B^m)\phi(B)(1-B^m)^D(1-B)^d y_t = c + \Theta(B^m)\theta(B)\xi_t, (3)$$

gdzie: y_t to wyrazy szeregu czasowego, ξ_t jest

procesem białego szumu z zerową średnią i wariancją σ^2 , m jest długością cyklu tygodniowego (168 h), B jest operatorem przesunięcia wstecz, d i D to rzędy różnicowania (zwykłego i sezonowego), $\phi(\cdot)$, $\Phi(\cdot)$, $\theta(\cdot)$ i $\Theta(\cdot)$ są odpowiednio wielomianami stopnia p , q , P i Q , a c jest stałą.

Współczynniki i rzędy modelu ARIMA estymowano w automatycznej procedurze opisanej w [8] i zaimplementowanej w pakiecie **forecast** w środowisku **R** [11]. Rzędy różnicowania d i D dobiera się tutaj stosując test pierwiastków jednostkowych (*KPSS unit-root test*) oraz rozszerzony test Canova-Hansena. Rzędy p , P , q i Q wyznacza się przeszukując w sposób zachłanny przestrzeń modeli w otoczeniu aktualnych wartości tych parametrów. Kryterium informacyjne Akaikego (AIC), zależne od dopasowania modelu do danych uczących i stopnia jego złożoności (liczby parametrów), służy do oceny modeli w tym procesie. Współczynniki wielomianów $\phi(\cdot)$, $\Phi(\cdot)$, $\theta(\cdot)$ i $\Theta(\cdot)$ estymuje się metodą największej wiarygodności. W badaniach symulacyjnych parametry modelu ARIMA estymowano na 12-tygodniowych fragmentach szeregu czasowego obciążeń bezpośrednio poprzedzających moment prognozy. Występujące w tych szeregach uczących przebiegi dni nietypowych zastępowano przebiegami przesuniętymi o tydzień wstecz.

Drugi zastosowany tutaj sposób dekompozycji pozwala uprościć model do postaci ARIMA(p, d, q):


$$\phi(B)(1-B)^d y_t = c + \theta(B)\xi_t, \quad (4)$$

Szereg czasowy poddaje się addytywnej

dekompozycji na trend, składową sezonową oraz składową resztową za pomocą metody STL opartej na ważonym lokalnym wygładzaniu (LOESS) opisanej szczegółowo w [3]. Procedura dekompozycji STL jest iteracyjna i polega na naprzemiennej estymacji trendu oraz składnika sezonowego. Składnik sezonowy rozbijany jest na n podszeregów, gdzie n jest liczbą obserwacji w jednym cyklu. Podszereg i -ty złożony jest z obserwacji występujących na i -tej pozycji w kolejnych cyklach. Podszeregi wygładzane są niezależnie, podobnie jak trend. Stosowana do wygładzania metoda LOESS estymuje krzywą regresji w każdym punkcie szeregu czasowego w oparciu o punkty chronologicznie najbliższe, ważąc ich udziały zależnie od ich odległości czasowej od estymowanego punktu. Wagi uzależnia się także od wartości składnika resztowego w danym punkcie.

Do atrakcyjnych cech STL zalicza się odporność na dane odstające i brakujące, możliwość dekompozycji szeregów czasowych z sezonowością o dowolnej częstotliwości oraz możliwość implementacji z wykorzystaniem metod numerycznych zamiast modelowania matematycznego. Dekompozycję fragmentu szeregu czasowego obciążeń KSE zilustrowano na rys. 1.

Po wykonaniu dekompozycji szereg zdesezonowany (po odjęciu składowej sezonowej) prognozuje się na następny okres (np. dobowy lub tygodniowy) używając niesezonowego modelu ARIMA. Następnie do tej prognozy dodaje się wygładzoną składową sezonową z ostatniego okresu danych historycznych.



Rys. 1. Dekompozycja szeregu czasowego obciążeń metodą STL.

3. BADANIA SYMULACYJNE

Opisane powyżej modele ARIMA przetestowano w zadaniach prognozowania dobowych przebiegów godzinowych obciążeń z wyprzedzeniem do 7 dni. Eksperymenty przeprowadzono na kilku zbiorach danych:

- KSE – obciążenia godzinowe KSE w latach 2002-2004. Próba testowa obejmowała dane z roku 2004 z wyjątkiem trzynastu dni nietypowych.
- SL1 – obciążenia godzinowe systemu lokalnego w okresie lipiec 2001 – grudzień 2002 (średnie obciążenie ok. 1200 MW). Próba testowa obejmowała dane z okresu lipiec – grudzień 2002 z wyjątkiem ośmiu dni nietypowych.
- SL2 – obciążenia godzinowe systemu lokalnego w okresie 1999 – 2001 (średnie obciążenie ok. 300 MW). Próba testowa obejmowała dane z roku 2001 z wyjątkiem trzynastu dni nietypowych.

Szeregi czasowe SL1 i SL2 są bardziej nieregularne niż KSE. Miarą nieregularności szeregu czasowego obciążeń elektroenergetycznych może być błąd prognozy naiwnej postaci: przebieg obciążenia w dniu i jest taki sam jak w dniu $i-7$. Błędy MAPE prognoz naiwnych wynosiły: dla KSE – 3,43%, dla SL1 – 4,96, a dla SL2 – 6,62%.

Dokładność modeli ARIMA porównano z dokładnością modelu opartego na sieci neuronowej typu wielowarstwowy perceptron (WP). Sieć uczy się odwzorowania obrazów wejściowych na składowe obrazy prognoz (przyjęto definicje obrazów (3) i (10) z [4]). Sieć uczona jest lokalnie, tzn. na zbiorze uczącym złożonym z $k = 12$ najbliższych sąsiadów testowego obrazu wejściowego, reprezentujących ten sam dzień tygodnia co obraz testowy. Dla każdego zadania prognostycznego (prognoza obciążenia w godzinie t doby j) buduje się odrębną sieć. Aby zapobiec przeuczeniu sieci zastosowano algorytm uczenia Levenberga-Marquardta z regularyzacją bayesowską, gdzie minimalizowana jest kombinacja liniowa błędu kwadratowego i kwadratów wag.

Ponieważ funkcja regresji modelowana jest lokalnie, z wykorzystaniem niewielkiej liczby punktów uczących, należy się spodziewać raczej prostej postaci tej funkcji, co implikuje niewielką liczbę neuronów. W badaniach wstępnych testowano sieci z różną liczbą neuronów. Jako optymalną wybrano sieć z jednym neuronem z sigmoidalną bipolarną funkcją aktywacji.

W tab. 1 zestawiono wyniki prognoz dla horyzontu jednodobowego – średni procentowy błąd absolutny (MAPE), odchylenie standardowe MAPE, średni błąd procentowy (MPE) i odchylenie standardowe MPE. Model z dekompozycją na 24 szeregi czasowe reprezentujące obciążenia w tych samych godzinach doby oznaczono symbolem ARIMA1, natomiast model z dekompozycją STL oznaczono symbolem ARIMA2. Tłustym drukiem w tab. 1 oznaczono wartości MPE nie różniące się istotnie od zera, które wskazują na nieobciążenie prognoz. Na rys. 2 pokazano dystrybuanty błędów.


Najmniejsze błędy MAPE dla danych KSE i SL2 wykazała sieć neuronowa, natomiast dla danych SL2 – model ARIMA2. Aby odpowiedzieć na pytanie czy różnice pomiędzy błędami APE prognoz wygenerowanych przez analizowane modele są istotne statystycznie użyto testów nieparametrycznych (błędy APE nie mają rozkładu normalnego): testu znaków do weryfikacji hipotezy zerowej, że różnice błędów mają zerową medianę oraz testu Wilcoxona do weryfikacji hipotezy, że rozkłady błędów mają jednakowe mediany. Testy przeprowadzono dla każdej pary modeli. Poza przypadkiem ARIMA1, ARIMA2 dla SL2 testy pozwoliły odrzucić hipotezy zerowe.

Błędy prognoz dla horyzontów od 1 do 7 dni pokazano na rys. 3. Przy zwiększaniu horyzontu prognozy obserwuje się szybszy wzrost błędu modelu WP niż modeli ARIMA. Warto zwrócić uwagę, że przy najdłuższych horyzontach modele przestają być konkurencyjne w stosunku do metod naiwnych.


Tabela 1

Wyniki prognoz

Model	KSE				SL1				SL2			
	$MAPE_{ist}$	σ_{MAPE}	MPE_{ist}	σ_{MPE}	$MAPE_{ist}$	σ_{MAPE}	MPE_{ist}	σ_{MPE}	$MAPE_{ist}$	σ_{MAPE}	MPE_{ist}	σ_{MPE}
ARIMA1	1,82	2,20	0,0005	0,0303	3,41	4,02	0,0038	0,0598	3,93	5,18	-0,0024	0,0664
ARIMA2	1,91	2,19	-0,0024	0,0306	2,89	3,60	0,0008	0,0541	3,93	5,59	-0,0053	0,0694
WP	1,51	1,93	0,0011	0,0245	3,39	4,59	0,0030	0,0570	3,01	3,85	0,0002	0,0489



Rys. 2. Dystrybuanty błędów.



Rys. 3. Błędy w zależności od horyzontu prognozy.

4. PODSUMOWANIE

W tej pracy przedstawiono klasyczne jednowymiarowe modele ARIMA do krótkoterminowego prognozowania obciążeń systemów elektroenergetycznych. Aby uprościć problem szeregi czasowe obciążeń zdekomponowano używając dwóch metod. Według pierwszej metody definiuje się 24 szeregi reprezentujące obciążenia w tej samej godzinie doby. Do prognozowania tych szeregów używa się 24 sezonowych modeli ARIMA. Drugi sposób dekompozycji rozбивa szereg na składowe: trendu, sezonową i resztową. Za pomocą modelu ARIMA (bez sezonowości) prognozuje się szereg zdesezonowany. Dla szeregu KSE obydwa sposoby dekompozycji dawały zbliżone rezultaty. Pozostałe szeregi były dokładniej modelowane przy wykorzystaniu drugiego sposobu dekompozycji. Dla krótkich horyzontów czasowych i szeregów KSE oraz SL2 modele ARIMA wykazały znacznie gorsze rezultaty od sieci neuronowej działającej na obrazach dobowych cykli szeregów obciążeń. Przy dłuższych horyzontach dokładność modeli ARIMA poprawia się w stosunku do sieci neuronowej, a nawet ją przewyższa.

Należy jednak zauważyć, że ARIMA pozwala

modelować jedynie liniowe zależności, podczas gdy sieci neuronowe są uniwersalnymi aproksymatorami. Ma to istotne znaczenie w przypadku modeli wielowymiarowych ze zmiennymi pogodowymi, których wpływ na obciążenie wyrażają nieliniowe zależności.

Problem doboru rzędów modelu ARIMA i estymacja jego parametrów jest zadaniem dość złożonym, który rozwiązano tutaj stosując automatyczną procedurę zaimplementowaną w środowisku **R**. Z uwagi na heurystyczne procedury przeszukiwania przestrzeni modeli nie ma jednak gwarancji, że użyte modele ARIMA są optymalne. Podobny problem występuje w sieciach neuronowych, gdzie dobiera się heurystycznie parametry strukturalne (liczbę neuronów) i w odrębnej procedurze parametry wewnętrzne (wagi) korzystając z gradientowych metod optymalizacji lokalnej. W obydwu modelach kontrolowano złożoność: za pomocą kryterium AIC w ARIMA i regularyzacji bayesowskiej w wielowarstwowym perceptronie. Skutkowało to oszczędniejszymi strukturalnie modelami, co implikuje redukcję błędu generalizacji.

Praca naukowa finansowana ze środków na naukę w latach 2010-2012 jako projekt badawczy nr N N516 415338.

LITERATURA

- [1] Al-Hamadi H.M., Soliman S.A.: Short-Term Electric Load Forecasting Based on Kalman Filtering Algorithm with Moving Window Weather And Load Model. *Electric Power Systems Research* 68, pp. 47-59, 2004.

- [2] Amaral L.F., Souza R.C., Stevenson M.: A Smooth Transition Periodic Autoregressive (STPAR) Model for Short-Term Load Forecasting. *International Journal of Forecasting* 24, pp 603-615, 2008.
- [3] Cleveland R.B., Cleveland W.S., McRae J.E., Terpenning I.: STL: A Seasonal-Trend Decomposition Procedure Based on Loess. *Journal of Official Statistics*, Vol. 6, No. 1, pp. 3-73, 1990.
- [4] Dudek G.: Przetwarzanie danych w oparciu o podobieństwo metodach prognozowania przebiegów dobowych zapotrzebowania na moc elektryczną. *Przegląd Elektrotechniczny*, r. 82, nr 9, str. 15-19, 2006.
- [5] Espinoza M., Joye C., Belmans R., De Moor B.: Short-Term Load Forecasting, Profile Identification, and Customer Segmentation: A Methodology Based on Periodic Time Series. *IEEE Transactions on Power Systems*, Vol. 20 (3), pp. 1622-1630, 2005.
- [6] Gross G., Galiana F.D.: Short-Term Load Forecasting. *Proceedings of the IEEE*, Vol. 75, No. 12, pp. 1558-1573, 1987.
- [7] Huang C.-M., Huang C.-J., Wang M.-L.: A Particle Swarm Optimization to Identifying the ARMAX Model for Short-Term Load Forecasting. *IEEE Transactions on Power Systems*, Vol. 20 (2), pp. 1126-1133, 2005.
- [8] Hyndman R.J., Khandakar Y.: Automatic Time Series Forecasting: The Forecast Package for R. *Journal of Statistical Software*, Vol. 27, issue 3, 2008.
- [9] Lee C.-M., Ko C.-N.: Short-Term Load Forecasting using Lifting Scheme and ARIMA Models. *Expert Systems with Applications* 38, pp. 5902-5911, 2011.
- [10] Nowicka-Zagrajek J., Weron R.: Modeling Electricity Loads in California: ARMA Models with Hyperbolic Noise. *Signal Processing* 82, pp. 1903-1915, 2002.
- [11] R Development Core Team: R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>.
- [12] Soares L.J., Medeiros M.C.: Modeling and Forecasting Short-Term Electricity Load: A Comparison of Methods with an Application to Brazilian Data. *International Journal of Forecasting* 24, pp. 630-644, 2008.
- [13] Weron R.: *Modeling and Forecasting Electricity Loads and Prices*. Wiley 2006.
- [14] Yang H.T., Huang C.M.: A New Short-Term Load Forecasting Approach using Self-Organizing Fuzzy ARMAX Models. *IEEE Transactions on Power Systems*, Vol. 18 (2), pp. 673-679, 2003.

ARIMA MODELS FOR SHORT-TERM LOAD FORECASTING

Key words: short-term load forecasting, ARIMA

Summary. Univariate autoregressive moving average models for short-term load forecasting are presented. Load time series show a trend and three seasonal patterns: annual, weekly and daily, which complicate the forecasting model construction. To simplify the forecasting problem time series were decomposed using two approaches. The first one consists in the decomposition a time series into separate series for each hour of a day. The second approach uses a local regression (LOESS) to decompose series into trend, seasonal component and error. Nonstationarity of the decomposed time series requires using an integrated ARMA model. The accuracy of the proposed methods were compared on application examples with an accuracy of the model based on neural network.

Grzegorz Dudek, (ur. w 1969 r.) tytuł magistra inżyniera (1994 r.) i doktora nauk technicznych (2003 r.) w dziedzinie elektrotechniki uzyskał na Politechnice Częstochowskiej. Od 1994 r. pracuje w Instytucie Elektroenergetyki P.Cz. jako pracownik naukowo-dydaktyczny. Jego zainteresowania naukowe skupiają się wokół metod rozpoznawania obrazów i sztucznej inteligencji oraz ich zastosowań w elektroenergetyce (prognozowanie zapotrzebowania, rozdział obciążeń, problemy optymalizacyjne). Dudek@el.pcz.czyst.pl.