Rafał Kasperowicz
Uniwersytet Ekonomiczny w Poznaniu

PROGNOZOWANIE ZAPOTRZEBOWANIA NA ENERGIĘ ELEKTRYCZNĄ – PRZEGLĄD BADAŃ

Uwagi wstępne

Analizowanie oraz prognozowanie zapotrzebowania na energię elektryczną to najważniejszy obszar badawczy w elektroenergetyce. Wynika to ze specjalnej właściwości energii elektrycznej, a mianowicie braku możliwości jej magazynowania (*The Business...* 2002, s. 1). Produkcja i zużycie energii elektrycznej związane są nierozerwalnie ze sobą w czasie, podaż w każdej chwili musi równoważyć popyt. Z tego powodu przedsiębiorstwa sektora elektroenergetycznego potrzebują różnego rodzaju prognoz. Z punktu widzenia elektroenergetyki takie prognozy można podzielić na dwa typy. Pierwszym są prognozy krótkookresowe, które w elektroenergetyce dotyczą minut, godzin bądź dni (Harvey i Koopman 1993, s. 1228), w przeciwieństwie do krótkiego okresu w prognozach zmiennych ekonomicznych[1]. Drugi typ to prognozy długoterminowe, które w przypadku prognozowania zapotrzebowania na moce produkcyjne zakładów energetycznych dotyczą miesięcy, kwartałów oraz lat (Smith 2000, s. 465). Prognozy te służą do planowania zatrudnienia oraz inwestycji w przeciwieństwie do krótkookresowych, które skupiają się na zapewnieniu płynności dostaw energii w systemie[2].

Prognozowanie zapotrzebowania na energię elektryczną stanowi niezwykle istotne oraz trudne zadanie dla branży elektroenergetycznej. Trudności wynikają

[1] Prognozując zmienne ekonomiczne, posługujemy się terminem okres krótki, gdy prognozujemy zachowanie danej zmiennej w następnym miesiącu, kwartale, roku.

[2] Prognozy krótkookresowe przeciwdziałają przerwom w dostawach energii elektrycznej oraz zapewniają bezpieczeństwo całego systemu elektroenergetycznego, związane jest to z reformami, jakie zachodzą na rynku elektroenergetycznym, który został zliberalizowany. W szczególności związek pomiędzy prognozą krótkookresową a rynkiem energii elektrycznej można zauważyć na rynku spot, który jest elementem gwarantującym bilansowanie się zapotrzebowania oraz popytu na energię elektryczną.

między innymi z tego, iż szereg czasowy charakteryzujący zapotrzebowanie wykazuje różne sezonowości. W przypadku energii elektrycznej możemy rozróżnić trzy typy sezonowości – dobową, tygodniową oraz roczną. Ponadto na taki szereg istotny wpływ mają także czynniki zewnętrzne takie, jak czynniki meteorologiczne czy ekonomiczne (Misiorek i Weron 2004, s. 780).

1. Modele prognozowania zapotrzebowania na energię elektryczną

W literaturze przedmiotu można odnaleźć wiele modeli wykorzystywanych do opisu oraz prognozy zapotrzebowania na energię elektryczną. Do najczęściej spotykanych metod zaliczyć można: modelowanie ekonometryczne w oparciu o szeregi czasowe; budowanie modeli autoregresji i średniej; aplikacje metod sztucznej inteligencji.

Techniki bazujące na sztucznej inteligencji dotyczą przede wszystkim sieci neuronowych. W latach dziewięćdziesiątych przeprowadzono wiele badań z użyciem tego typu modeli, jednak jak dotąd znaleziono niewiele dowodów potwierdzających wyższość tego typu modeli nad standardowymi metodami prognostycznymi (Misiorek i Weron 2004, s. 780). Sztuczne sieci neuronowe są to sieci, których węzły są elementami przetwarzającymi lub operacyjnymi, nazywanymi sztucznymi neuronami. Proste w swym działaniu neurony za pomocą oddziaływania na siebie w nieliniowy sposób, mają możliwość „nauczenia się" aproksymować dowolną funkcję wielu zmiennych. Zdolność sieci do uogólniania wiedzy oraz wykrywanie zależności między zmiennymi doprowadzają do rozwiązania zadanego problemu (Lasom, Pyrczak i Trąbka 2001, s. 200). Każda sieć neuronowa zbudowana jest z trzech podstawowych, połączonych ze sobą elementów – warstwy wejściowej, ukrytej oraz wyjściowej. Dane wejściowe podawane są na pierwszą warstwę, po czym przetwarzane są przez warstwy ukryte i przechodzą do warstwy wyjściowej, gdzie przetworzony sygnał zostaje odebrany (Lasom, Pyrczak i Trąbka 2001, s. 201; Stern 1996, s. 205–206). Wielkość parametrów wejściowych, wyjściowych oraz ukrytych danej sieci jest zdeterminowana przez problem, jaki dana sieć ma rozwiązywać (Stern 1996; Suarez-Farinas, Pedreira i Medeiros 2004; Hansen, McDonald i Nelson). Sztuczne sieci neuronowe w elektroenergetyce najczęściej używane są do prognozowania krótkookresowego (Malko, Mikołajczak i Skorupski 1994; 1996).

Do opisu krótkookresowego zachowania się zapotrzebowania na energię elektryczną w czasie, użyteczne są także modele autoregresji i średniej ruchomej ARMA i ARIMA[3]. Mogą być one stosowane do modelowania szeregów stacjo-

[3] ARMA (AutoRegressive Moving Average), ARIMA (AutoRegressive Integrated Moving Average).

narnych. Równanie autoregresji i średniej ruchomej ARMA powstaje poprzez połączenie opisu dynamicznego zachowania się zmiennej ekonomicznej w czasie przy pomocy modelu autoregresji z modelem średniej ruchomej. Otrzymany model ARMA procesu y ma następującą postać (Chow 1995, s. 233):

$$y_t = a_1 y_{t-1} + ... + a_p y_{t-p} + \varepsilon_t + b_1 \varepsilon_{t-1} + ... + b_q \varepsilon_{t-q} \quad (1)$$

gdzie:
y_t, y_{t-1}, y_{t-p} – wartość zmiennej prognozowanej w odpowiednim okresie,
a, b – parametry modelu,
p, q – wielkość opóźnienia,
$\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-q}$ – składnik resztowy w odpowiednim okresie.

Część autoregresyjna modelu jest kombinacją liniową wartości p poprzedzających wartości modelowanego procesu y, natomiast część średniej ruchomej to kombinacja liniowa bieżącej oraz q poprzedzających impulsów białego szumu ε_t. Biały szum jest traktowany tutaj jako wejście modelu, lecz nie jest obserwowalny. Sam model w procesie prognozowania generuje empiryczne przybliżenie procesu ε, jako ciąg błędów chwilowych prognozy w wyprzedzeniu jednostkowym. Proces ten nazywany jest procesem reszt i przy dobrym dopasowaniu całego modelu jest bliski białemu szumowi (Zawada 2002, s. 39). Model procesu zapotrzebowania mocy y konstruowany jest przez kolejne przekształcenia z wykorzystaniem analizy korelacji, które uwzględniają zmienność okresową szeregu zapotrzebowania na energię elektryczną (Zawada 2002, s. 39–40). Z kolei modele ARIMA są modelami ogólniejszymi, stosowanymi w przypadku, gdy szereg zmiennej prognozowanej zawiera trend, a więc jest niestacjonarny (Box i Jenkins 1976). Trzeba wtedy poprzez operację różnicowania przekształcić dany szereg w szereg stacjonarny. Wszystkie modele autokorelacji i średniej ruchomej można zapisać przy użyciu uniwersalnej notacji ARIMA (p, d, q) (red. Cieślak 2001, s. 90), gdzie p oznacza rząd autoregresji, d to krotność różnicowania, a q to wielkość opóźnień średniej ruchomej. Z tego wynika, iż model ARMA to inaczej ARIMA (p, 0, q), w której nie dokonuje się procedury różnicowania.

Omówiona procedura już od wielu lat znajduje zastosowanie w prognozowaniu krótkookresowego zapotrzebowania na energię elektryczną. Między innymi stosowali ją Nelson i Peak (Nelson, Peak i Uhler 1989, s. 91–107) w 1989 roku, w 1993 Kokkelenberg i Mount (Kokkelenberg i Mount 1993, s. 1132–1139), w 1999 Chavez i Bernat (Chavez, Bernat i Colla 1999, s. 183–198), a w 2002 Ghosh i Das (Ghosh i Das 2002, s. 1055–1059). W 1985 roku Ackerman (Ackerman 1985) dokonał porównań stosowania metod autoregresyjnych oraz średnich ruchomych w prognozowaniu zapotrzebowania na energię elektryczną. Uznał, że połączenie obydwu metod zapewnia uzyskanie najlepszych efektów w prognozowaniu.

Następną metodą prognozowania zapotrzebowania na energię elektryczną jest modelowanie ekonometryczne polegające na poszukiwaniu związków pomiędzy zapotrzebowaniem a różnymi wskaźnikami. Wskaźnikami mogą być tutaj różne zmienne makroekonomiczne, jak i te, które charakteryzują czynniki wpływające na popyt na energię elektryczną. Najczęściej spotykanymi tutaj modelami są liniowe modele regresji wielorakiej, za pomocą których można prognozować krótkookresowe oraz długookresowe zachowanie zmiennej referencyjnej.

Jednym z najczęściej wskazywanych, długookresowych modeli ekonometrycznych zużycia energii elektrycznej w literaturze polskiej, jest model zaprezentowany w pracach J. Dziechciarza (Dziechciarz 1981; 1983). Model ten bazuje na danych z okresu 1946–1978 i opisuje roczne zużycie energii elektrycznej w ujęciu makro, jego ogólna postać przedstawia się następująco:

$$Y = \sum_{i=1}^{k} \alpha_i X_i + \varepsilon \tag{2}$$

gdzie:
Y – roczne zużycie energii elektrycznej w Polsce w latach 1946–1978 w mld KWh,
α_i – parametry modelu,
X_i – zmienne objaśniające,
k – liczba uwzględnionych zmiennych objaśniających,
ε – składnik losowy modelu.

Podczas estymacji modeli przyjęto wstępnie 21 potencjalnych zmiennych objaśniających, do których należą zmienne o charakterze ekonomicznym oraz demograficznym. Na ich podstawie zbudowano szereg modeli, których składowymi były różne kombinacje zmiennych objaśniających. Następnie na podstawie wyestymowanych modeli dokonywano prognoz. Do zmiennych objaśniających zaliczono między innymi:
- ludność Polski w milionach osób;
- dochód narodowy Polski w cenach stałych (1950–100);
- inwestycje w gospodarce narodowej;
- wartość brutto środków trwałych;
- wartość brutto produkcyjnych środków trwałych;
- produkcja globalna przemysłu;
- produkcja czysta przemysłu polskiego;
- inwestycje w przemyśle;
- zatrudnienie;

– zmienna zero-jedynkowa informująca o ograniczeniach w dostawach energii elektrycznej – 1 dla lat, w których takie ograniczenia występowały, a w pozostałych przypadkach 0.

Z kolei w literaturze światowej często natrafia się na model, w którym zapotrzebowanie na energię elektryczną jest funkcją wskaźników aktywności ekonomicznej oraz cen energii. Jednym z najczęściej wskazywanych artykułów prezentujących to podejście jest artykuł K. Fatai, L. Oxley i F.G. Scimgeour (2003, s. 75–102), w którym zapotrzebowanie na energię elektryczną rozpatrywano w trzech zakresach – zapotrzebowanie gospodarstw domowych, przemysłu oraz globalne. Model zapotrzebowania gospodarstw domowych wzorowany jest na modelu Beenstocka (1999, s. 168–183), a sformułowano go w następujący sposób (Fatai, Oxley i Scimgeour 2003, s. 78):

$$HLD = HLD(C, P_r, P_o; T) + \mu \tag{3}$$

gdzie:
HLD – konsumpcja energii elektrycznej gospodarstw domowych,
C – wydatki konsumentów,
P_r – ceny energii elektrycznej,
P_o – ceny innych dóbr,
T – warunki atmosferyczne (temperatura),
μ – błąd modelu.

Analogicznie zbudowano model zapotrzebowania na przemysłową energię elektryczną, który przedstawia się następująco:

$$IND = IND(Q, P_{id}, P_o; T) + \varepsilon \tag{4}$$

gdzie:
IND – konsumpcja przemysłowej energii elektrycznej,
Q – produkcja przemysłowa,
P_{id} – ceny przemysłowej energii elektrycznej,
P_o – relatywne ceny innych dóbr,
T – warunki atmosferyczne (temperatura),
ε – błąd modelu.

Z połączenia obydwu przedstawionych modeli powstał model globalnego zapotrzebowania na energię elektryczną o następującej postaci (Fatai, Oxley i Scrimgeour 2003, s. 78):

$$TFC = TFC(G, P_{tf}, P_o; T) + \eta \tag{5}$$

gdzie:
P_{tf} – indeks cen energii elektrycznej,
G – całkowita produkcja oszacowana za pomocą realnego PKB,
η – błąd modelu.

Autorzy w swoim artykule nawiązują do koncepcji przedstawionej przez Engle'a i Grangera (Engle, Granger i Hallman 1989, s. 45–62) z 1989 roku. Zaprezentowali oni koncepcję integracji oraz kointegracji w prognozowaniu krótko- oraz długookresowego zapotrzebowania na energię elektryczną. Koncepcję tę K. Fatai, L. Oxley i F.G. Scrimgeour porównują z innymi metodami estymacji powyższych modeli, do których zaliczają zmodyfikowaną metodę najmniejszych kwadratów FMLS[4] oraz modelowanie autoregresji z rozłożonymi opóźnieniami ARDL[5].

Omawiając zapotrzebowanie na energię elektryczną, warto zwrócić uwagę na krótkookresowy, godzinowy model zapotrzebowania przedstawiony przez Ramanathana, Engle'a, Grengera, Vahid-Araghi'ego oraz Brace'a (1997, s. 161–174) w 1997 roku. Model ten oparty jest na regresji wielorakiej i może być zastosowany w różnego typu przedsiębiorstwach do prognozowania godzinowego zapotrzebowania na energię elektryczną przez dane przedsiębiorstwo. Model w swojej bazowej postaci wyrażony jest następującą funkcją (Ramanathan i in. 1997, s 161–174):

$$HOUR1 = aDETRRMINISTIC + bTEMPERATURE + \\ + cLOAD + dPASTERRORS + \varepsilon \quad (6)$$

gdzie:
aDETERMINISTIC – to zmienne o charakterze deterministycznym, czyli zmienne, które są doskonale prognozowane. Do takich zmiennych w przypadku prognozowania zapotrzebowania na energię elektryczną zaliczyć można dzień tygodnia, miesiąc w roku oraz rok. Wynika to ze specyficznej sezonowości energii elektrycznej.
bTEMPERATURE – to zmienne określające temperaturę, jej zmienność. Jest to oczywista zmienna, ponieważ im temperatura wyższa tym zapotrzebowanie niższe.
cLOAD – to zmienna określająca zapotrzebowanie na energię elektryczną o godzinie 8 rano. Im wyższe zapotrzebowanie poranne tym wyższe dzienne.

[4] *Fully Modyfied Least Squares* (Philips i Hansen 1990, s. 99–124).
[5] *AutoRegressive Distributed Lag* (Pesaran, Shin, Smith 1996).

dPASTERRORS – to już znane błędy wcześniejszych prognoz z tego samego dnia poprzedniego tygodnia.

ε – błąd modelu.

Zaprezentowany model wykazał bardzo dobre właściwości prognostyczne w prognozowaniu zapotrzebowania z godziny na godzinę. Pomimo szerokiej gamy parametrów metoda estymacji modelu jest bardzo prosta – regresia OLS[6]. Dzięki temu model łatwo zaadoptować w różnych przedsiębiorstwach na ich własny użytek.

Z kolei, rozpatrując analizy długoterminowe, można dokonać podziału stosowanych metodologii prognozowania na sześć kategorii:

1) projekcje trendu,
2) projekcje ekonometryczne,
3) analizy *End-Use* (końcowego zużycia),
4) modele mieszane,
5) modele dynamiki systemów (Craig, Gadgil i Koomey 2002, s. 99–101),
6) analizy scenariuszowe (Craig, Gadgil i Koomey 2002, s. 99–101).

Do najczęściej stosowanych należą cztery pierwsze, w których projekcje trendu zajmują szczególną pozycję. Są to najstarsze i najprostsze metody związane z długookresowym prognozowaniem zapotrzebowania na energię ogółem, w której energia elektryczna posiada określony udział (Starr 1979, s. 153–190). Wraz z rozwojem techniki komputerowej rozwinęło się podejście ekonometryczne. Modele ekonometryczne bazują na analizie regresji, która pozwala na stosowanie różnego rodzaju zmiennych objaśniających. Przykładem jest tu przedstawiony wcześniej model J. Dziechciarza skomponowany z szeregu zmiennych ekonomicznych. Analiza ekonometryczna oczywiście nie wyklucza analiz trendu, które także mogą stanowić część tego typu badań (Huss 1985, s. 217–239).

Szczególnym przypadkiem badań w prognozowaniu zapotrzebowania na energię elektryczną są analizy End-Use. Modele End-Use tłumaczą zapotrzebowanie na energię gospodarstw domowych bądź poszczególnych sektorów przemysłowych na poziomie jej ostatecznego zużycia (Bartels i Fiebig 1998, s. 52). Oznacza to, iż prognozowana jest na przykład wielkość zużycia energii elektrycznej w celach grzewczych, pracy maszyn, oświetlenia i tym podobne. Ogólnie rzecz biorąc podejście to odpowiada na pytanie – „Kto, w jakim celu i jaką ilość energii zużyje?". Podejście End-Use stosowane jest od początku lat 80. Między innymi stosowane było przez M. Parti i C. Parti (1980, s. 309–324), D.J. Aignera, C. Sorooshiana i P. Erwina (1984), przez D.J. Aignera i P. Schonfelda (1990), R. Bartelsa i D.G. Fiebiga (1998).

[6] *Ordinary Least Squares* – metoda najmniejszych kwadratów.

Następna kategoria to modele mieszane. Jak sama nazwa wskazuje są to pewnego rodzaju „hybrydy" wcześniejszych podejść. Ten rodzaj wielopłaszczyznowej analizy stosowany jest coraz częściej przez przedsiębiorstwa, instytucje rządowe oraz społeczne.

Podsumowanie

Modelowanie zapotrzebowania na energię elektryczną posiada obszerną bibliografię w literaturze światowej i polskiej. W zaprezentowanym opracowaniu przedstawiono tylko część stosowanych modeli, które posłużyły jako reprezentatywna grupa omawianego zagadnienia.

Jak już na wstępie wspomniano, klasyfikacja analiz zapotrzebowania na energię elektryczną opiera się na zakresie czasowym, któremu odpowiadają prowadzone badania – krótkookresowe bądź długookresowe. Po przeprowadzeniu obszernych studiów literaturowych stwierdzono, iż większość modeli krótkookresowych konstruowana jest analogicznie do modelu Engle'a, Grangera, Vahid-Araghi'ego, Brace'a i Ramanathana (1997). W ich budowie można wyróżnić część autoregresyjną, która opisuje zjawisko na podstawie jego wcześniejszych wartości, oraz część poświęconą czynnikom sezonowym. W przypadku energii elektrycznej sezonowość to najprostsza cecha do zaobserwowania, ponieważ jest ona dość oczywista. Konsumpcja w dzień jest większa niż w nocy (sezonowość dobowa), w weekend jest mniejsza niż w pozostałych dniach tygodnia (sezonowość tygodniowa), zimą jest większa niż latem (sezonowość roczna – zależna głównie od rocznego rozkładu temperatur).

Przedstawiony przegląd technik długookresowego modelowania zapotrzebowania na energię elektryczną sprawia, iż dostrzegalny jest wyraźnie brak analiz cykliczności zapotrzebowania na energię elektryczną. Badania takie z pewnością dopełnią kanon prowadzonych analiz oraz pozwolą poznać zależności pomiędzy zmianami koniunkturalnymi w gospodarce a cyklicznością zapotrzebowania na energię elektryczną.

Bibliografia

Ackerman, G. (1985), *Short-term load prediction for electric-utility control of generating units*, w: D.W. Bunn, E.D. Farmer (ed.), *Comparative Models for Electrical Load Forecasting*, Wiley, New York.

Aigner, D.J. i Schonfeld, P. (1990), *Experimental design for direct metering of residential electricity end-uses*, w: J.J. Gabszewicz, J.F. Richard, L.A. Worsley (ed.), *Economic Decision-making: Games, Econometrics and Optimization*, North-Holland Publishing Company, Amsterdam.

Aigner, D.J., Sorooshian, C. i Kerwin, P. (1984), *Conditional analysis for estimating residential end-use loads profiles*, The Energy Journal vol. 5, issue no. 3, s. 81–98.

Bartels, R. i Fiebig, D.G. (1998), Residential *End-Use Electricity Demand: Results from a Designer Experiment*, The Energy Journal vol. 21, no. 2, s. 51–81.

Beenstock, M., Goldin, E. i Nabot, D. (1999), *The demand for electricity in Israel*, Energy Economics no. 21, issue 2, s. 168–183.

Box, G.E.P. i Jenkins, G.M. (1976), *Time Series Analysis:Forecasting and Control*, Holden Day, San Francisco.

Chavez, S.G., Bernat, J.X. i Colla H.L. (1999), Forecasting *of energy production and consumption in Asturis*, Energy no. 24, s. 183–198.

Chow, G.C. (1995), *Ekonometria*, Wydawnictwo Naukowe PWN, Warszawa.

Cieślak, M. (2001), *Prognozowanie gospodarcze. Metody i zastosowanie*, Wydawnictwo Naukowe PWN, Warszawa.

Craig, P.P., Gadgil, A. i Koomey, J.G. (2002), *What Can History Teach Us? A Retrospective Examination of Long-Term Energy Forecasts for the United States*, The Annual Review of Energy and the Environment vol. 27, s. 83–118.

Dziechciarz, J. (1981), *Ekonometryczne modele zużycia energii elektrycznej w Polsce,* Prace Naukowe Akademii Ekonomicznej im. Oskara Lanego we Wrocławiu nr 185, Wrocław.

Dziechciarz, J. (1983), *Własności prognostyczne zużycia energii elektrycznej w Polsce*, Prace Naukowe Akademii Ekonomicznej im. Oskara Lanego we Wrocławiu nr 220, Wrocław.

Engle, R.F., Granger, C.W.J. i Hallman, J.J., *Merging Short- and Long-run Forecasts: An Application of Seasonal Cointegration to Monthly Electricity Sales Forecasting*, Journal of Econometrics no. 40(1), s. 45–62.

Fatai, K., Oxley, L. i Scrimgeour, F.G. (2003), *Modeling and Forecasting the Demand for Electrycity in New Zeland: A Comparision of Alternative Approaches*, The Energy Journal vol. 24, no. 1, s. 75–102.

Ghosh, S. i Das, A. (2002), *Short-run electricity demand forecasts in Maharashtra*, Applied Economics no. 34, s. 1055–1059.

Hansen, J.V., McDonald, J.B. i Nelson, R.D., *Time Series Prediction with Genetic-Algorithm Designed Neural Networks: An Empirical Comparison with Modern Statistical Models*, Computational Intelligence vol. 15, no. 3, s. 171–184.

Harvey, A. i Koopman, S.J. (1993), *Forecasting Hourly Electricity Demand Using Time Varying Spliners*, Journal of the American Statistical Association, December, vol. 88, no. 424, s. 1228–1236.

Huss, W.R. (1985), *Comparative analysis of company forecasts and advanced time series techniques using annual electric utility energy sales data*, International Journal of Forecasting no. 1, s. 217–239.

Kokkelenberg, E.C. i Mount, T.D. (1993), *Oil shocks and demand for electricity*, The Energy Journal no. 14, s. 113–138.

Lasoń, W., Pyrczak, W. i Trąbka, J. (2001), *Inspiracje biologiczne w sieciach neuronowych i algorytmach genetycznych*, w: L.H. Chaber (red.), *Polskie doświadczenia w kształtowaniu społeczeństwa informacyjnego: dylematy cywilizacyjno-kulturowe*, materiały ogólnopolskiej konferencji naukowej, Kraków, wrzesień, s. 199–208.

Malko, J., Mikołajczak, H. i Skorupski, W. (1996), *Problem dokładności modelowania krótkoterminowego godzinowego obciążeń elektroenergetycznych za pomocą sieci neuronowych warstwowych*, III sympozjum: Prognozowanie w elektroenergetyce, Częstochowa.

Malko, J., Mikołajczak, H. i Skorupski, W. (1994), *Sztuczne sieci neuronowe jako narzędzie prognozowania zapotrzebowania mocy w systemie elektroenergetycznym*, II sympozjum: Prognozowanie w elektroenergetyce, Częstochowa.

Misiorek, A. i Weron, R. (2004), *Modelowanie sezonowości a prognozowanie zapotrzebowania na energię elektryczną*, Energetyka, grudzień, s. 759–764.

Nelson, C.R., Peak, S.C. i Uhler R.G. (1989), *The NERC fan in retrospect*, The Energy Journal no. 10, s. 91–107.

Parti, M. i Parti, C. (1980), *The total and appliance specyfic conditional demand for electricity In the household sektor*, Bell Journal of Economics no. 11, s. 309–321.

Pesaran, M.H., Shin, Y. i Smith, R.J. (1996), *Testing for the Existence of a Long-Run Relationship*, Departament of Applied Economics, Working Paper no. 9622, University of Cambridge, Cambridge.

Philips, P.C.B., Hansen, B.E. (1990), *Statistical inference witch I(1) processes*, Review of Economic Studies no. 57.

Ramanathan, R., Engle, R.F., Granger, C.W.J., Vahid-Araghi, A. i Brace, C. (1997), *Short-run Forecasts of Electricity Loads and Peaks, International Journal of Forecasting* no. 13, s. 161–174.

Smith, M. (2000), *Modeling and Short-Term Forecasting of New South Wales Electricity System Load*, Journal of Business & Economic Statistics, October, vol. 18, no. 4, s. 465–478.

Starr, C. (1979), *Energy planning: a nation at risk*, w: C. Starr (ed.), *Current Issues in Energy: A Selection of Papers by Chauncy Starr*, Pergamon New York, s. 153–190.

Stern, H.S. (1996), *Neural Networks in Applied Statistics*, American Statistical Association and the American Society for Quality Control, Technometrics, August, vol. 38, no. 3, s. 205–214.

Suarez-Farinas, M., Pedreira, C.E. i Medeiros, M.C. (2004), *Local Global Neural Networks: A New Approach for Nonlinear Time Series Modeling*, Journal of the American Statistical Association, December, vol. 99, no. 468, s. 1092–1107.

The Business Cycle in the Power Industry (2002), Energy Security Analysis ESAI, July 16.

Zawada M. (2002), *Modelowanie i prognozowanie zapotrzebowania na energię elektryczną w aspekcie rozwoju rynku energii elektrycznej w Polsce*, Wydawnictwo Wyższej Szkoły Zarządzania i Marketingu w Sosnowcu, Sosnowiec.

FORECASTING THE DEMAND FOR ELECTRIC ENERGY – RESEARCH REVIEW

Summary

Analysing and forecasting the demand for electric energy is the most important research area in the electric power industry. It results from the special feature of electric energy that is lack of the possibility to store it. The supply has to balance the demand at every moment, that is why production and consumption of electric energy are particularly interlinked. Companies of the electric power industry need to diversify forecasts for this reason.

The article presents models which are most often applied to forecasting consumption of electric energy. It is possible to divide the forecasting models into two types. The first one short-term forecasts which refer to minutes, hours or days and the second type - long-time forecasts which refer to months, quarters and years.