

Tomasz POPLAWSKI*, Kazimierz DAŚAL**, Jacek ŁYP**

Długoterminowa prognoza mocy szczytowej dla KSE

STRESZCZENIE. Charakterystyczną cechą systemu elektroenergetycznego jest jego ciągła zmienność.

W celu poprawnego prowadzenia eksploatacji systemu elektroenergetycznego jak również planowania jego rozwoju niezbędne jest wykonywanie prognoz elektroenergetycznych. Wykonanie poprawnej prognozy dla systemu jest zadaniem niełatwym i wymagającym dużego doświadczenia, wiedzy i wyczucia. Aby w sposób świadomy móc regulować i przewidywać procesy zachodzące w systemie elektroenergetycznym niezbędne są prace z dziedziny analizy i prognozy obciążeń elektroenergetycznych. W artykule przedstawiono nowy model prognostyczny oparty o rozkład kanoniczny wektora zmiennych losowych. Jest to nowa metoda prognostyczna, w wyniku której można otrzymać długoterminowe prognozy mocy szczytowej dla KSE.

SŁOWA KLUCZOWE: prognozowanie w elektroenergetyce, szeregi czasowe, rozkład kanoniczny

1. Prognozowanie w elektroenergetyce

Różnorodne aspekty zjawisk gospodarczych związanych z kształtowaniem zapotrzebowania na energię elektryczną wymagają różnych informacji o istocie tego procesu. Można wyróżnić dwa podstawowe rodzaje zjawisk, w których wymaga się informacji

* Prof. nadzw. dr hab. inż., ** Dr inż. — Instytut Elektroenergetyki, Politechnika Częstochowska, Zakład Urządzeń i Gospodarki Elektroenergetycznej, Częstochowa; e-mail: poptom@el.pcz.czyst.pl

dotyczących przyszłości procesu zapotrzebowania na energię elektryczną są to: planowanie rozwoju systemu elektroenergetycznego oraz planowanie eksploatacji systemu elektroenergetycznego.

Intensywna ewolucja sektora elektroenergetyki wpływa na cele, metody oraz narzędzia prognozowania w elektroenergetyce. Cele na najbliższą dekadę zostały sformułowane pod koniec lat dziewięćdziesiątych dla Europejskiej Sieci Tematycznej: Inteligentne Systemy Predykcji (IFS – *Intelligent Forecasting Systems*) jako swoisty plan działania na najbliższe lata. Wśród tzw. subprojektów narodowych jako przyszłościowe określa się:

- ✧ inteligentne systemy prognozowania w przemyśle i elektroenergetyce,
- ✧ zastosowania metod sztucznej inteligencji w systemach elektroenergetycznych,
- ✧ modelowanie i predykcja krótkoterminowego zapotrzebowania energii elektrycznej,
- ✧ czynniki krytyczne prognozowania w systemach elektroenergetycznego prognozowania na zderegulowanym rynku energii elektrycznej,
- ✧ krótkoterminowe prognozowanie cen na rynku transakcji natychmiastowych,
- ✧ modele predykcji dobowych krzywych obciążenia z wykorzystaniem sztucznych sieci neuronowych,
- ✧ prognozowanie obciążeń szczytowych ze składowymi niestochastycznymi procesami,
- ✧ zastosowanie systemów inteligentnych w monitorowaniu i diagnostyce.

Złożoność problematyki prognostycznej implikuje podział i klasyfikacje stosowanych metod ze względu na:

- ✧ rozmiar badanego systemu elektroenergetycznego,
- ✧ horyzont czasowy prognozy oraz zakres informacji wejściowych i wyjściowych,
- ✧ model predykcji.

W aktualnych realiach rozwoju rynku energii elektrycznej w Polsce rozmiar systemu może zmieniać się w szerokich granicach. Biorąc pod uwagę spójny obszar (system), można wyselekcjonować dla niego szereg wielkości opisujących jego: dynamikę, strukturę, zmienność, a bazując na tych relacjach wyodrębnić różne systemy elektroenergetyczne: krajowy system elektroenergetyczny (KSE), spółki dystrybucji energii (SD), okręgi elektroenergetyczne, województwa, miasta, gminy wiejskie itp. Do celów dotyczących planowania będą rozważane systemy w skali kraju i jego regionów, gdyż na takim poziomie są rozpatrywane decyzje, związane z ogólną strategią rozwoju społeczno-gospodarczego.

W przypadku planowania eksploatacji oraz rozwoju systemu elektroenergetycznego opracowano wiele metod prognozowania opisanych szeroko w literaturze fachowej [5, 6, 7, 8, 11, 12, 14] opartych m.in. o prognozowanie realistyczne i badawcze, punktowe i przedziałowe, ilościowe i jakościowe. Grupą najbardziej rozpowszechnioną są metody ilościowe (statystyczne), określające prawdopodobieństwo przyszłych zdarzeń na podstawie danych historycznych. W ramach metod ilościowych stosuje się wiele technik wnioskowania (np. analiza szeregów czasowych [6], analiza funkcji trendu [5], analiza Fouriera [15]), z których każda może się opierać na różnych miarach (średnie ruchome proste, średnie ważone) i modelach (model wygładzania wykładniczego, model liniowy Holta, model Wintersa [17], model trendu pełzającego czy model wskaźnikowy itd.). Odrębną grupę stanowią metody i narzędzia prognostyczne dotyczące szeroko rozumianej sztucznej inteligencji (*Artificial Intelligent* – AI) [8, 11, 16]. W celach prognostycznych proponuje się

używanie sztucznych sieci neuronowych wspomaganych algorytmami genetycznymi, logiki rozmytej oraz hybryd łączących wszelkiego rodzaju techniki [5, 7, 8, 11, 16]. Dobór metod jest podyktowany przyjętymi parametrami prognozy i jej horyzontem czasowym. Metody ilościowe stosuje się wtedy, gdy istnieje dostatecznie dużo danych źródłowych do analiz. Gdy danych jest mało, są niezbyt wiarygodne bądź zgoła brak ich w ogóle, zastosowanie znajdują metody jakościowe opierające się na opracowanych metodach dotyczących funkcji punktowych [5, 7, 10, 18].

W artykule proponuje się budowę modelu prognostycznego opartego o rozkład kanoniczny wektora zmiennych losowych. Jest to autorskie podejście prognostyczne, gdyż dotychczas model ten nie był używany do długoterminowych prognoz szczytu rocznego w KSE.

2. Rozkład kanoniczny wektora zmiennych losowych w procesie predykcji

Zakłada się, że pewien proces opisany jest wektorem losowym X , którego składowe X_i ($i = 1, 2, \dots, m$) są ze sobą skorelowane. Przekształcenie wektora X o składowych skorelowanych na inny wektor V , o składowych nieskorelowanych, które są funkcjami liniowymi składowych wektora X , można wykonać stosując metodę rozkładu kanonicznego. Poniżej za [3, 5, 14] przedstawiono ideę metody.

Składowe wektora V wyznaczymy z układu równań:

$$\begin{aligned} V_{1n} &= X_{01n} \\ V_{2n} &= X_{02n} - a_{21}V_{1n} \\ V_{3n} &= X_{03n} - a_{31}V_{1n} - a_{32}V_{2n} \\ &\vdots \quad \quad \quad \vdots \quad \quad \quad \vdots \quad \quad \quad \vdots \quad \quad \quad \vdots \\ V_{in} &= X_{0in} - a_{i1}V_{1n} - a_{i2}V_{2n} + \dots - a_{i,i-1}V_{(i-1)n} \end{aligned} \tag{1}$$

Układ równań układu (1) można zapisać w skrócie:

$$V_{in} = X_{0in} - \sum_{j=1}^{i-1} a_{ij}V_{jn} \tag{2}$$

$$i = 1, 2, \dots, m; \quad j = 1, 2, \dots, i - 1; \quad n = 1, 2, \dots, N$$

gdzie: i – numer składowej X_i ,
 m – liczba składowych wektorów X, V ,
 n – kolejna obserwacja,

Wynikiem rozkładu kanonicznego otrzymamy symetryczną macierz współczynników a_{ij} , rozkładu kanonicznego oraz składowe V_i , wektora V .

Pełny opis procedury rozkładu kanonicznego wraz z jej zastosowaniem w procesie predykcji zamieszczono w [5].

W tak skonstruowanym modelu w procesie prognozy mogą wystąpić dwa przypadki:

1. Znana jest realizacja tylko pierwszej składowej X_1 , wówczas wszystkie pozostałe składowe X_2, \dots, X_{m-1}, X_m , są prognozowane.
2. Znane są realizacje składowych, wówczas prognozowanych jest $(m - p)$ zmiennych.

W prognozie zmienne X_1, X_2 , aż do 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:

$$\hat{X}_i = \sum_{j=1}^{i-1} a_{ij} V_j + \hat{V}_i + \bar{x}_{X_i} \quad (6)$$

Zazwyczaj prognozuje się tylko ostatnią składową X_m , a pozostałe X_1, X_2, \dots, X_{m-1} , są wejściami do prognozy i traktowane są jako zmienne objaśniające. Fakt, że dla prognozy wystarczająca jest znajomość scenariusza (prognozy) tylko pierwszej zmiennej w modelu jest cenną właściwością tego modelu, umożliwiającą prognozę w sytuacji ograniczonego dostępu do informacji w stosunku do informacji zawartej w historii procesu. W każdym kolejnym równaniu (6), nieznaną pozostaje wartość \hat{V}_i , której wartość wynika z ogólnej zależności:

$$V_i = f_i(X_{01}, X_{02}, \dots, X_{0i}) \quad (7)$$

W praktyce modelowania z zależności (7) nie można było skorzystać ze względu na brak korelacji pomiędzy zmiennymi objaśniającymi. Jednakże brak korelacji między zmiennymi V_i nie implikuje braku zależności między nimi. Można zatem wyznaczyć (na podstawie danych historycznych) empiryczne warunkowe rozkłady częstości i na ich podstawie dystrybuanty o następującej postaci:

$$\begin{aligned} F_1(v_2 | V_1 < v_1) & \quad (8) \\ F_2(v_3 | V_1 < v_1, V_2 < v_2) & \\ \dots & \\ F_{m-1}(v_m | V_1 < v_1, V_2 < v_2, \dots, V_{m-1} < v_{m-1}) & \end{aligned}$$

Tę właściwość wykorzystano w zastosowaniu praktycznym uwzględniając związki (8), funkcje gęstości prawdopodobieństwa buduje się według następującej ogólnej formuły:

$$F_i(V_{i+1} | x_{0igr} < X_{0i} \leq x_{0ig,r+1}) \quad i = 1, 2, \dots, m - 1 \quad (9)$$

Z przedstawionego sposobu wyznaczania prognoz wynika, że macierze częstości i macierze dystrybuant warunkowych zbudowane na podstawie historii procesu będą miały

istotny wpływ na dokładność predykcji, dlatego przy budowie modelu należy uwzględnić sposób ich tworzenia.

3. Dobór istotnej liczby zmiennych objaśniających do modelu rozkładu kanonicznego

W literaturze [2, 3, 4, 9] podano opis wielu metod doboru składowych do różnych modeli ekonometrycznych. Najpełniej opracowane są metody dla modeli liniowych lub sprowadzalnych do liniowych jednorównaniowych. Podstawowy postulat dotyczący zmiennych – silna korelacja między każdą zmienną objaśniającą i zmienną objaśnianą i jednocześnie słaba korelacja między zmiennymi objaśniającymi, sprawia, iż zdecydowana większość metod doboru zmiennych wykorzystuje w mniej lub bardziej jawny sposób, właściwości współczynnika korelacji liniowej. Rozwiązaniem uznawanym za optymalne jest jak najmniejsza liczba nieskorelowanych wzajemnie składowych objaśniających, a w możliwie maksymalnym stopniu skorelowanych ze zmienną objaśnianą, które z wymaganą dokładnością wyjaśniają wariację badanego procesu. Ta ogólna definicja, przekłada się w literaturze omawiającej tę problematykę na zbiór kilkunastu, a z różnymi modyfikacjami, zbiór kilkudziesięciu metod doboru zmiennych.

Do jednej ze skuteczniejszych, a jednocześnie w miarę prostych w implementacji metod według [9] zaliczono Metodę pojemności integralnych informacji Hellwiga. Jest to metoda, która zdobyła największe uznanie wśród ekonometryków prowadzących badania empiryczne. Świadczy o tym duża liczba publikacji, z których wynika, że metoda ta zdoła w pełni egzamin praktyczny. Tą metodę również zastosowano do określenia istotnej liczby zmiennych w modelu rozkładu kanonicznego.

Punktem wyjścia jest tutaj oszacowanie macierzy R i wektora R_0 . Macierzą R nazywamy macierz współczynników korelacji między poszczególnymi zmiennymi objaśniającymi, którą można zapisać następująco:

$$R = \begin{bmatrix} 1 & r_{12} & \cdot & \cdot & \cdot & r_{1k} \\ r_{21} & 1 & \cdot & \cdot & \cdot & r_{2k} \\ \cdot & \cdot & 1 & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & 1 & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & 1 & \cdot \\ r_{k1} & r_{k2} & \cdot & \cdot & \cdot & 1 \end{bmatrix} \quad (10)$$

Natomiast wektor R_0 jest wektorem współczynników korelacji między zmienną objaśnianą, a kolejnymi zmiennymi objaśniającymi. Wektor ten możemy zapisać macierzowo wzorem:

$$R_0 = \begin{bmatrix} r_1 \\ r_2 \\ \cdot \\ \cdot \\ \cdot \\ r_k \end{bmatrix} \quad (11)$$

gdzie: k – liczba zmiennych objaśniających

Następnie przystępuje się do obliczenia tzw. indywidualnych pojemności nośników informacji X_j o zmiennej endogenicznej Y , wchodzących w skład różnych kombinacji utworzonych z elementów danego zbioru zmiennych objaśniających. Wiadomo, że ogólna liczba tych kombinacji wynosi 2^{k-1} .

Zmienna X_j jest tym lepszym nośnikiem informacji o zmiennej Y , im bliższy jedności jest moduł współczynnika korelacji liniowej r_j . Pamiętać należy również o tym, że zmienna X_j jest tylko wtedy czystym nośnikiem informacji, gdy nie jest skorelowana z innymi zmiennymi objaśniającymi. Gdy jednak zmienna X_j jest z nimi skorelowana, wtedy uważamy, że X_j jest zanieczyszczonym nośnikiem informacji o zmiennej endogenicznej Y .

Zanieczyszczeniem indywidualnego nośnika informacji X_j nazywa się wielkość:

$$g_j = \frac{1}{k-1} \sum_{i \neq j} |r_{ij}| \quad (12)$$

Jak łatwo sprawdzić, zawsze zachodzi nierówność $0 \leq g_j \leq 1$, przy czym $g_j = 0$ wtedy, gdy X_j jest czystym nośnikiem informacji o zmiennej Y , oraz $g_j = 1$ wtedy, gdy zanieczyszczenie nośnika informacji jest całkowite.

Pojemność indywidualna nośnika informacji X_j o zmiennej Y oblicza się z następującego wzoru:

$$h_j = \frac{r_j^2}{1 + \sum_{i \neq j} |r_{ij}|} = \frac{r_j^2}{1 + (k-1)g_j}; \quad (i, j = 1, \dots, k; i \neq j) \quad (13)$$

Z kolei oblicza się pojemności integralne nośników informacji za pomocą następującego wzoru:

$$H_m = \sum_{j=1}^k h_j = \sum_{j=1}^k \frac{r_j^2}{1 + \sum_{i \neq j} |r_{ij}|}; \quad (m = 1, 2, \dots, 2^k - 1) \quad (14)$$

Można wykazać, że parametr H jest wielkością unormowaną, zawartą w przedziale $\langle 0, 1 \rangle$.

Jeżeli ta pojemność jest bliska jedności, oznacza to, że zmienne wchodzące w skład danej kombinacji dostarczają niemal pełnego zasobu informacji o zmiennej endogenicznej Y . Wynika stąd, że wprowadzenie do modelu innej kombinacji zmiennych objaśniających może tylko pogorszyć naszą wiedzę o zmiennej Y .

Przedstawiona metoda postępowania pozwala na wybór optymalnej kombinacji zmiennych objaśniających. Kryterium wyboru takiej kombinacji można zapisać następująco:

$$H_{m0} = \max_m H_m \quad (15)$$

gdzie: H_{m0} – kombinacja optymalnych zmiennych.


4. Dane wejściowe do modelu i ich transformacja

Dane statystyczne wykorzystywane w procedurach predykcji mogą mieć charakter szeregów czasowych lub danych przekrojowych oraz przekrojowo-czasowych. Najczęściej spotykanym typem danych ekonomicznych są informacje o zdarzeniach gospodarczych w postaci uporządkowanego według czasu ciągu liczb. W celu zbudowania modelu prognostycznego niezbędne jest merytoryczne wyselekcjonowanie historycznego materiału statystycznego do wyznaczenia parametrów strukturalnych budowanych modeli predykcji oraz weryfikacji tych modeli pod kątem ich dopasowania do wartości rzeczywistych.

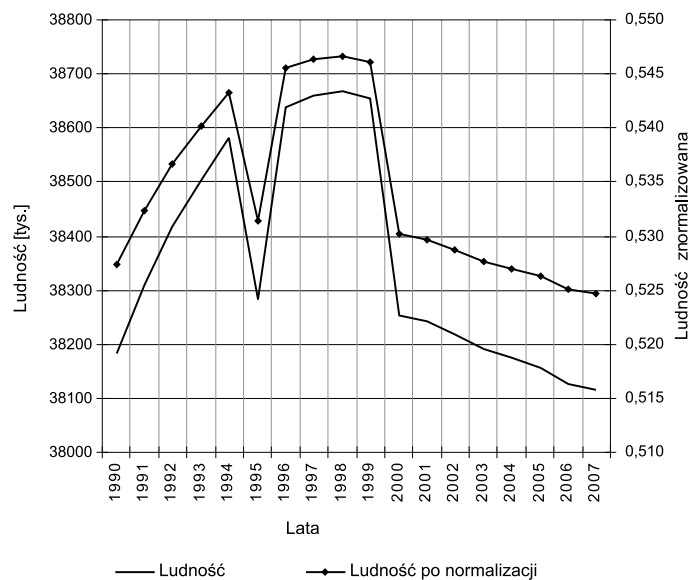
W przypadku długoterminowych prognoz szczytu rocznego dla KSE za dane historyczne mogące mieć istotny wpływ uznano:

1. Zużycie energii elektrycznej brutto w KSE.
2. Zużycie energii elektrycznej w przemyśle.
3. Zużycie energii elektrycznej w grupie – pozostali odbiorcy.
4. Produkt krajowy brutto w mln zł.
5. Dynamikę produktu krajowego brutto (poprzednia wartość = 100).
6. Ludność Polski.
7. Energię pierwotną ogółem w Polsce.
8. Szczyty roczne w KSE.

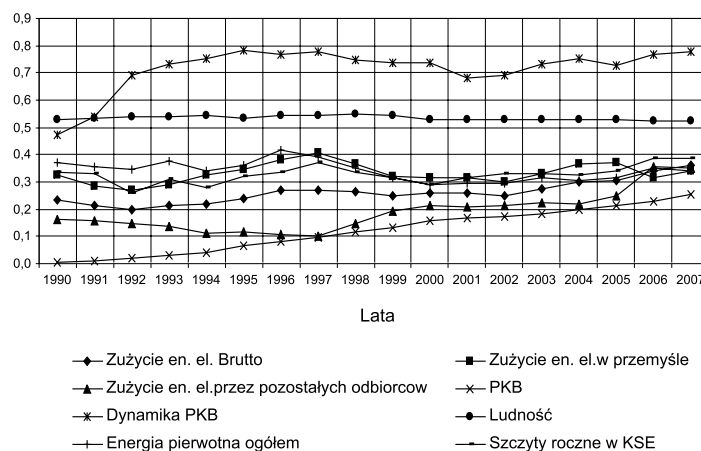
W przypadku modeli wielowymiarowych (np. regresja wieloraka lub model rozkładu kanonicznego) do objaśnienia zmiennej prognozowanej można wyselekcjonować wiele zmiennych w sposób merytoryczny powiązanych ze zmienną objaśnianą [2, 9]. Do zdefiniowania stanu tych zmiennych używane są ich miary. Ważnym jest by miary tych zmiennych były takie same. Oczywistym faktem jest, że opisanie dowolnej wybranej zmiennej za pomocą jednego wymiaru jest mało precyzyjne i najczęściej nie jest opisem wystarczającym. Do dobrego opisu zmiennej konieczne są jeszcze inne wymiary, np.: wartość średnia, wartość minimalna, wartość maksymalna, itp. Wielość tych wymiarów może być właściwie dowolna dlatego ważne jest by były one wyraźnie wyodrębnione od innych i nie pokrywały się wzajemnie w żadnym stopniu. Wymiarem może być więc



Rys. 1. Zużycie energii elektrycznej brutto w Polsce. Przebieg rzeczywisty i przekształcony
 Fig. 1. Gross consumption of electric energy in Poland. The true time dependency and transformed



Rys. 2. Ludność w Polsce. Przebieg rzeczywisty i przekształcony
 Fig. 2. The population of Poland. The true time dependency and transformed



Rys. 3. Wybrane zmienne do modelu po transformacji

Fig. 3. The selected variables to the model after transformation

również każda różnica, iloraz lub kombinacja wymiarów między dwoma dowolnie zdefiniowanymi punktami w badanej przestrzeni lub inne dowolnie zdefiniowane wartości.

Dzięki normalizacji [9, 13, 19], zmienne (wymiary) można ze sobą porównywać, przypisać odpowiednie wagi, sumować, itp. Ułatwia to również optymalizację np. wag dla zmiennych w przypadku ich doboru lub ustalenia ich siły oddziaływania na zmienną objaśnianą. Normalizacja powoduje, że maksymalny zakres wahań każdej zmiennej jest taki sam. Otrzymujemy wektory, których wartości cech są zawarte w przedziale $\langle 0,1 \rangle$. Transformacja ta jest przeprowadzana według wzoru:

$$a_i = \frac{a_i - a_{i \min}}{a_{i \max} - a_{i \min}} \quad (16)$$

gdzie: $a_{i \max}$ – jest maksymalną wartością występującą w zbiorze dla i -tej cechy,
 $a_{i \min}$ – jest minimalną wartością dla i -tej cechy.

Operacja normalizacji wykonywana jest dla wszystkich wektorów w zbiorze zmiennych objaśnianych. Nie uwzględnia rozkładu wartości danej cechy, w związku z tym w przypadku wystąpienia w danej cesze wartości znacznie różnych od przeciętnej, nastąpi ściśnięcie tych wartości w bardzo wąskim przedziale.

5. Weryfikacja modelu

Weryfikacji modelu rozkładu kanonicznego dokonano na przykładzie długoterminowej prognozy szczytu rocznego dla KSE do 2030 roku. Jak wspomniano wcześniej w opisie


modelu jest on szczególnie przydatny w przypadku ubogiej wiedzy o badanym obiekcie, który w tym przypadku będzie krajowym systemem elektroenergetycznym. Wykorzystuje się w takim przypadku fakt, że generuje on pewien proces losowy. Nie znając analitycznych związków między zmiennymi objaśniającymi, takich aby można było podać pełny matematyczny opis obiektu, ale dysponując pewną wiedzą o tym obiekcie (znając przykładowo czynniki mające wpływ na rozważany obiekt) można wykorzystać rozkład kanoniczny zmiennych oraz warunkowe rozkłady realizacji tych zmiennych do opisu badanych procesów.

Zakłada się wykonanie wielu symulacji procesu w oparciu o postać kanoniczną wektora losowego. Proces prognozowany traktuje się jako część stanu obiektu, zaś odpowiednio przetworzone obserwacje statystyczne (historyczne) jako wejście obiektu. Po ustaleniu składowych modelu (zmiennych objaśniających), model wymaga również ustalenia kolejności zmiennych w wektorze stanowiącym wejście do modelu. Jest to jedno z kluczowych zagadnień, gdyż jak wcześniej wspomniano, buduje się i wykorzystuje w procesie prognozy, warunkowe rozkłady prawdopodobieństwa.

Zbiór danych wejściowych do wyselekcjonowania po przetworzeniu obejmował kilkanaście zmiennych. Z nich ostatecznie za pomocą opisanej metody Hellwiga wybrano 7 istotnie oddziałujących na zmienną prognozowaną, a ich kolejność została ustalona metodą funkcji Q opisaną szczegółowo w [3, 4].

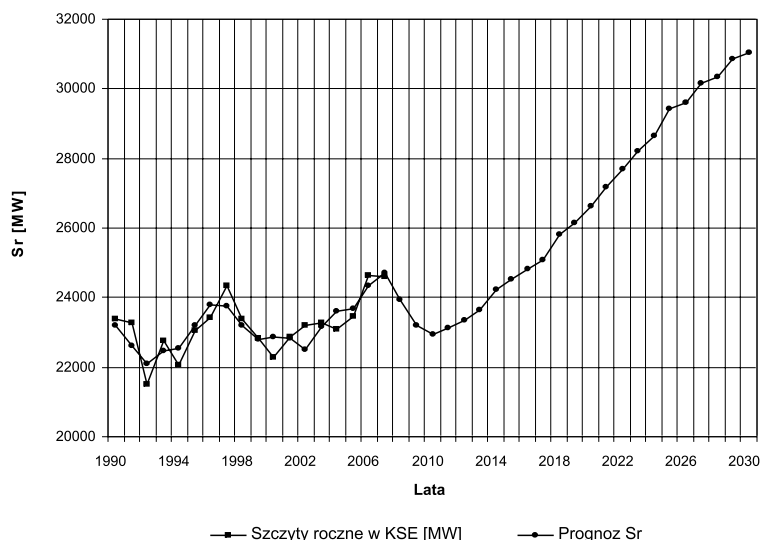
Dla zobrazowania wpływu poprawnego doboru liczby zmiennych do modelu i ich kolejności na jakość modelu na rysunku 4 przedstawiono przebieg rzeczywisty mocy szczytowej w KSE z lat 1990 do 1997 oznaczony symbolem S_r oraz przebieg uzyskany z modelu MRK dla najlepszego wariantu doboru kolejności składowych objaśniających (błąd MAPE dopasowania modelu 1,14%) oznaczony symbolem $S_{r\text{ pro}}$. Z wielu symulacji kolejności wejść wybrano dla zobrazowania istotności wpływu wariant najlepszy dopasowania.

Prognozę mocy szczytowej dla KSE do 2030 roku skonstruowano w ten sposób, że zmienne objaśniające do modelu przyjęto dla najlepszego wariantu dopasowania modelu



Rys. 4. Zmienność rocznej mocy szczytowej w Polsce. Przebieg rzeczywisty i przebiegi uzyskane z modelu MRK

Fig. 4. Variability of the annual peak power in Poland. The true time dependency and dependencies obtained from the MRK model



Rys. 5. Prognoza rocznych szczytów obciążenia w KSE.
Przebieg rzeczywisty i przebiegi uzyskane z modelu MRK

Fig. 5. Forecast of the annual peaks of power in KSE. The true curve and forecasting curves

i kolejności wejść ustalonej metodą funkcji Q (X_4 – Produkt krajowy brutto w mln zł, X_1 – Zużycie energii elektrycznej brutto w KSE, X_7 – Energia pierwotna ogółem w Polsce). Na rysunku 5 prognozę mocy szczytowej dla KSE do 2030 roku oznaczono symbolem Prognóz S_r .

Scenariusze prognoz zmiennych objaśniających przyjęto z opracowania ARE [1]. Na rysunku 5 przedstawiono graficznie wyniki uzyskanych prognoz.

Podsumowanie

W dotychczasowej praktyce, dotyczącej długoterminowych prognoz mocy szczytowej w KSE używano wielu modeli prognostycznych, które w zależności od rodzaju techniki prognostycznej posiadały różne ograniczenia.

Wyższosc przedstawionego powyżej modelu rozkładu kanonicznego w stosunku do innych modeli predykcji jest związana między innymi z tym, że poprzez odpowiednie operacje na zmiennych objaśniających, uwalnia się je od korelacji. Jest to bardzo pozytywny efekt, gdyż w ten sposób pozbywamy się bardzo niekorzystnego zjawiska w prognozowaniu jakim jest współliniowości zmiennych. Dodatkowym atutem modelu może być również to, że do prognozy w wielowejściowym modelu niezbędna jest jedynie jedna zmienna sterująca zadana w postaci scenariusza prognozy, natomiast pozostałe zmienne objaśniające mogą być prognozowane przez sam model rozkładu kanonicznego.

Literatura

- [1] Agencja Rynku Energii S.A. Prognoza zapotrzebowania na paliwa i energię dla Polski do 2030 roku. Warszawa, luty 2009.
- [2] BARCZAK A.S., BIOLIK J., 1999 – Podstawy ekonometrii. Wydawnictwo Uczelniane Akademii Ekonomicznej w Katowicach, Katowice.
- [3] DAŚAL K., POPLAWSKI T., 2009 – Dobór zmiennych wejściowych w modelu prognoz długoterminowych funkcją Q. Przegląd Elektrotechniczny 85, nr 2, s. 144–148.
- [4] DAŚAL K., 2003 – Metoda doboru wejść w prognozowaniu krótkoterminowym obciążenia systemu elektroenergetycznego dla modelu rozkładu kanonicznego wektora losowego. Rozprawa doktorska. Częstochowa.
- [5] DOBRZAŃSKA I., DAŚAL K., ŁYP J., POPLAWSKI T., SOWIŃSKI J., 2002 – Prognozowanie w elektroenergetyce. Zagadnienia wybrane. Wydawnictwo Politechniki Częstochowskiej. Częstochowa.
- [6] DUDEK G., 2004 – Wybrane metody analizy szeregów czasowych obciążenia elektroenergetycznych. Prognozowanie w Elektroenergetyce PE'2004, s. 116–125, Wydawnictwo Politechniki Częstochowskiej, Częstochowa.
- [7] DUDEK G., 2001 – Analiza opartych na teorii chaosu metod długoterminowego prognozowania zapotrzebowania na energię elektryczną – model Schustera. Materiały konferencyjne: Metody i Systemy Komputerowe w Automatyce i Elektrotechnice, t. 1, s. 90–92, Częstochowa, Poraj.
- [8] DUDEK G., 2007 – Analiza modelu krótkoterminowego prognozowania obciążenia systemów elektroenergetycznych opartego na klasteryzacji rozmytej. Badania Operacyjne i Decyzje, nr 2, s. 15–34.
- [9] GRABIŃSKI T., WYDYMUS S., ZELIĄS A., 1982 – Metody doboru zmiennych w modelach ekonometrycznych. PWN Warszawa.
- [10] ŁYP J., 1996 – Procedury korzystania z funkcji punktowych w prognozowaniu przebiegów dobowych obciążenia systemów lokalnych. Materiały konferencyjne PE'96. Częstochowa.
- [11] ŁYP J., 2005 – Artificial Neural Networks in Forecasting of Energy Prices on the Electricity Balancing Market. The IIIrd International Scientific Symposium Elektroenergetika, Słowacja. Stará Lesná.
- [12] MALKO J., 1995 – Wybrane zagadnienia prognozowania w elektroenergetyce. OWPW, Wrocław.
- [13] MASTERS T., 1996 – Sieci neuronowe w praktyce. WNT Warszawa.
- [14] POPLAWSKI T., DAŚAL K., 2008 – Problematyka programowania rozwoju systemu elektroenergetycznego w Polsce. Polityka Energetyczna t. 11, z. 1, s. 385–398.
- [15] POPLAWSKI T., DAŚAL K., 2006 – Model harmonicznych w prognozowaniu giełdowych cen energii elektrycznej, Przegląd Elektrotechniczny 82, nr 9, s. 38–40.
- [16] POPLAWSKI T., 2005 – Application of the Takagi-Sugeno (TS) fuzzy logic model for load curves prediction in the local power system. IIIrd International Scientific Symposium Elektroenergetika 2005. Stara Lesna Slovak Republic.
- [17] POPLAWSKI T., 2002 – Wykorzystanie multiplikatywnego modelu Wintersa do tygodniowych prognoz przebiegów obciążenia lokalnych systemów elektroenergetycznych. Prognozowanie w elektroenergetyce PE, s. 109–116.
- [18] POPLAWSKI T., 1997 – Funkcje punktowe jako nowa droga podejścia do analizy i prognozy obciążenia w systemie; VIII Międzynarodowa Konferencja Naukowa Aktualne Problemy w Elektroenergetyce APE'97. Gdańsk–Jurata, 11–13 czerwca.

[19] RUTKOWSKA D., PILIŃSKI M., RUTKOWSKI L., 1997 – Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. PWN Warszawa.

Tomasz POPLAWSKI, Kazimierz DAŚAL, Jacek ŁYP

The long-term forecast of electricity consumption in Poland

Abstract

The characteristic feature of a power engineering system is its constant variability. In order to operate a power engineering system, as well as to plan its development it is necessary to carry out forecasts. Working out a correct forecast is an uneasy task that requires a lot of experience, knowledge and intuition. In order to be able to control and foresee the processes that occur in a power engineering system it is necessary to undertake research in the field of analyses of power loads.

In the paper a new forecasting model, based on the canonical distribution of a vector of random variables, has been presented. It is a new forecasting method, able to predict long-term forecasts on peak power load of power engineering system in Poland.

KEY WORDS: Long-term load forecasting in electric power engineering, time series, canonical distribution