



**Instytut Gospodarki
Surowcami Mineralnymi
i Energią**
Polskiej Akademii Nauk

ROZPRAWA DOKTORSKA

Mgr inż. Rafał Czapaj

Prognozowanie krótkoterminowego
zapotrzebowania na moc elektryczną
metodą ważonych współczynników
funkcji autokorelacji cząstkowej

Promotor pracy:
Prof. dr hab. inż. Jacek Kamiński

Promotor pomocniczy:
Dr inż. Maciej Sołtysik

Kraków 2021

Spis treści

Wykaz ważniejszych skrótów i pojęć w języku polskim	5
Wykaz ważniejszych skrótów i pojęć w języku angielskim.....	9
Wykaz symboli	11
Wprowadzenie	12
1. Tło problematyki prognozowania zapotrzebowania na moc elektryczną	18
1.1. Prognozowanie w kontekście ekonometrii	18
1.2. Prognozowanie w kontekście statystyki	29
1.3. Prognozowanie w kontekście energetyki i elektroenergetyki	30
1.3.1. Zapotrzebowanie na moc elektryczną a obciążenie systemu elektroenergetycznego	30
1.3.2. Dynamika obciążenia systemu elektroenergetycznego w czasie... ..	31
1.3.3. Gospodarka rynkowa a gospodarka planowa	47
1.4. Prognozowanie na tle planowania zapotrzebowania na moc elektryczną w Krajowym Systemie Elektroenergetycznym	48
1.5. Pokrywanie zapotrzebowania na moc elektryczną w systemie elektroenergetycznym.....	53
1.5.1. Środki pokrywania zmienności obciążenia dobowego	53
1.5.2. Środki wyrównywania profilu obciążenia dobowego systemu elektroenergetycznego	54
1.5.3. Horyzonty prognostyczne	55
1.5.4. Prognozowanie krótkoterminowe w elektroenergetyce.....	56
1.5.5. Metody analiz i prognozowania w elektroenergetyce	57
2. Stan badań w obszarze prognozowania zapotrzebowania na moc elektryczną w systemie elektroenergetyczny	63
3. Opracowanie modelu matematycznego do prognozowania zapotrzebowania na moc elektryczną wykorzystującego metodę ważonych współczynników funkcji autokorelacji cząstkowej	77
3.1. Zarys teoretyczny	77
3.2. Podstawy teoretyczne funkcji korelacji.....	80
3.2.1. Korelacja dwóch zmiennych i funkcja autokorelacji ACF	80
3.2.2. Funkcja autokorelacji cząstkowej PACF.....	81
3.2.2.1. Metoda inwersji bezpośredniej.....	82
3.2.2.2. Metoda Równań Yule – Walker’a.....	84
3.3. Koncepcja i założenia metody ważonych współczynników funkcji autokorelacji cząstkowej	88

3.4.	Formuły matematyczne modelu wykorzystującego metodę ważonych współczynników funkcji autokorelacji cząstkowej.....	89
3.4.1.	Podjęcie klasyczne	89
3.4.2.	Podjęcie krokowe	89
3.4.3.	Kalibracja modelu matematycznego.....	90
3.5.	Założenia i dane wejściowe.....	90
3.6.	Procedura badawcza	92
3.7.	Podjęcie klasyczne a podjęcie krokowe	92
4.	Walidacja opracowanego modelu do prognozowania zapotrzebowania na moc elektryczną wykorzystującego metodę ważonych współczynników funkcji autokorelacji cząstkowej	94
4.1.	Dopuszczalność prognoz	94
4.1.1.	Kryteria dopuszczalności prognoz w literaturze przedmiotu	94
4.1.2.	Założenia względem kryterium dopuszczalności prognoz	94
4.1.3.	Analiza dopuszczalności ogólna.....	95
4.1.4.	Analiza dopuszczalności dla typów dni.....	96
4.1.5.	Analiza dopuszczalności dla dni świątecznych i niestandardowych	98
4.2.	Walidacja modelu ważonych współczynników funkcji autokorelacji cząstkowej – studium przypadku Krajowego Systemu Elektroenergetycznego	100
4.2.1.	Skuteczność prognozowania PSE S.A. dla Krajowego Systemu Elektroenergetycznego	100
4.2.2.	Skuteczność prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej	105
4.2.3.	Skuteczność modelu ważonych współczynników a skuteczność PSE S.A. dla Krajowego Systemu Elektroenergetycznego	111
4.2.4.	Hybrydowa integracja podjęcia PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej....	117
4.3.	Walidacja modelu ważonych współczynników funkcji autokorelacji cząstkowej – studium przypadku wybranych zagranicznych systemów elektroenergetycznych	121
4.3.1.	Skuteczność prognozowania dla zagranicznych systemów elektroenergetycznych	121
4.3.2.	System szwedzki.....	123
4.3.3.	System francuski.....	126
4.4.	Walidacja modelu ważonych współczynników funkcji autokorelacji cząstkowej – porównanie z wybranymi metodami autoregresyjnymi.....	129
4.4.1.	Wybrane metody i modele prognozowania autoregresyjnego.....	129

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

4.4.2. Skuteczność i ranking wybranych metod i modeli prognozowania autoregresyjnego	131
4.4.3. Skuteczność prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej na tle metody ARIMA	133
4.4.4. Skuteczność prognozowania metodą naiwną	138
4.4.5. Skuteczność prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej na tle metody naiwnej z opóźnieniem siedmiu dób	139
4.4.6. Skuteczność prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej na tle metody naiwnej z opóźnieniem jednej doby	145
4.5. Podsumowanie dla trzech obszarów walidacji opracowanego modelu...	151
Podsumowanie i wnioski końcowe	156
Bibliografia	163
Spis rysunków	182
Spis tabel	183

Wykaz ważniejszych skrótów i pojęć w języku polskim

Skrót	Wyjaśnienie/tłumaczenie
AG	– Algorytm genetyczny;
AR (1) zc	– Model liniowy autoregresji pierwszego poziomu (1) [zmienna czasowa];
AR (1) zz	– Model liniowy autoregresji pierwszego poziomu (1) [zmienna zależna];
ARlag 1	– Model autoregresji (z opóźnieniem);
Arwp (1)	– Model liniowy autoregresji wyższego poziomu (poz. 1);
Arwp (2)	– Model liniowy autoregresji wyższego poziomu (poz. 2);
Arwp (3)	– Model liniowy autoregresji wyższego poziomu (poz. 3);
Arwp (4)	– Model liniowy autoregresji wyższego poziomu (poz. 4);
Arwp (5)	– Model liniowy autoregresji wyższego poziomu (poz. 5);
b.d.	– Brak danych;
BD	– Prognoza bardzo dokładna;
BPKD	– Bieżący Plan Koordynacyjny Dobowy;
BSSZ	– Sztuczna sieć neuronowa (zespół – BSS);
czw.	– Czwartek – dzień roboczy (bez uwzględnienia dni świątecznych i niestandardowych S01 – S16);
D	– Prognoza dokładna;
DE	– Dekompozycja empiryczna;
DP	– Prognoza dopuszczalna;
ENW	– Estymator Nadaraya – Watson;
FR	– Francja;
Godzina doby	– 00:00:00 – 00:59:59 – pierwsza godzina doby; 01:00:00 – 01:59:59 – druga godzina doby; 02:00:00 – 02:59:59 – trzecia godzina doby; 03:00:00 – 03:59:59 – czwarta godzina doby; 04:00:00 – 04:59:59 – piąta godzina doby; 05:00:00 – 05:59:59 – szósta godzina doby; 06:00:00 – 06:59:59 – siódma godzina doby; 07:00:00 – 07:59:59 – ósma godzina doby; 08:00:00 – 08:59:59 – dziewiąta godzina doby; 09:00:00 – 09:59:59 – dziesiąta godzina doby; 10:00:00 – 10:59:59 – jedenasta godzina doby; 11:00:00 – 11:59:59 – dwunasta godzina doby; 12:00:00 – 12:59:59 – trzynasta godzina doby; 13:00:00 – 13:59:59 – czternasta godzina doby; 14:00:00 – 14:59:59 – piętnasta godzina doby; 15:00:00 – 15:59:59 – szesnasta godzina doby; 16:00:00 – 16:59:59 – siedemnasta godzina doby; 17:00:00 – 17:59:59 – osiemnasta godzina doby; 18:00:00 – 18:59:59 – dziewiętnasta godzina doby; 19:00:00 – 19:59:59 – dwudziesta godzina doby; 20:00:00 – 20:59:59 – dwudziesta pierwsza godzina doby;

	21:00:00 – 21:59:59	– dwudziesta druga godzina doby;
	22:00:00 – 22:59:59	– dwudziesta trzecia godzina doby;
	23:00:00 – 23:59:59	– dwudziesta czwarta godzina doby;
GPZ	–	Główny Punkt Zasilania;
GW	–	Gigawat;
IMGW	–	Instytut Meteorologii i Gospodarki Wodnej (Państwowy Instytut Badawczy);
KSE	–	Krajowy System Elektroenergetyczny;
KT	–	Korekcja temperaturowa;
Lasso	–	Regresja najmniejszej bezwzględnej selekcji i operatora zawężania;
LL	–	Losowy las;
LR	–	Logika Rozmyta;
MF	–	Metoda falkowa;
MFN	–	Metoda efektu niedawności;
MLPZ1	–	Sztuczna sieć neuronowa (zespół – Perceptron wielowarstwowy 1);
MN	–	Metoda naiwna;
MN(-1)	–	Model wykorzystujący metodę naiwną z opóźnieniem 1 doby;
MN(-7)	–	Model wykorzystujący metodę naiwną z opóźnieniem 7 dób;
MNKB	–	Model wykorzystujący metodę najmniejszych kwadratów błędów;
MNO	–	Metoda naiwna opóźniona;
MNU	–	Metoda naiwna uśredniona;
MP	–	Model przemysłowy;
MRK	–	Metoda rozkładu wektora kanonicznego;
MRO	–	Model regresji ogólnej;
MRO2K	–	Model 2 – krokowy regresji ogólnej;
MROP	–	Model pełny regresji ogólnej;
MW	–	Megawat;
n.d.	–	Nie dotyczy;
$n+1$	–	Doba dostawy energii elektrycznej dla której opracowywana jest prognoza w dobie n ;
$n-1$	–	Doba poprzedzająca dostawę energii elektrycznej;
ND	–	Prognoza niedopuszczalna;
niedz.	–	Niedziela – dzień weekendu (bez uwzględnienia dni świątecznych i niestandardowych S01 – S16);
NSWP	–	Najbliższych sąsiadów z wejściami pogodowymi dla analizy podobieństw;
OK	–	Odbiorcy komunalni;
OSP	–	Operator Systemu Przesyłowego;
PKD	–	Plan Koordynacyjny Dobowy;
P	–	Moc czynna będąca obciążeniem Krajowego Systemu Elektroenergetycznego;
PL	–	Polska;
PMA	–	Półparametryczny model addytywny;
PO	–	Podobieństwo obrazów;

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

- pon. – Poniedziałek – dzień roboczy uwzględniający poniedziałki następujące po dniu świątecznym i niestandardowym (bez uwzględnienia dni świątecznych i niestandardowych S01 – S16);
- PSE S.A. – Polskie Sieci Elektroenergetyczne S.A.;
- pt. – Piątek – dzień roboczy (bez uwzględnienia dni świątecznych i niestandardowych S01 – S16);
- PU – Przycinanie uśredniane;
- RCNK – Regresja cząstkowych najmniejszych kwadratów;
- RG – Regresja grzbietowa;
- RK – Regresja krokowa;
- RR – Regresja rozmyta;
- RSG – Regresja składowych głównych;
- RW – Regresja wieloraka;
- S01 – Nowy Rok – Święto oficjalne nieruchome – dzień wolny od pracy;
- S02 – Trzech Króli – Święto oficjalne nieruchome – dzień wolny od pracy;
- S03 – Wielkanoc – Święto oficjalne ruchome – dzień wolny od pracy;
- S04 – Drugi dzień Świąt Wielkanocnych – Święto oficjalne ruchome – dzień wolny od pracy;
- S05 – 1. Maja – Święto Pracy – Święto oficjalne nieruchome – dzień wolny od pracy;
- S06 – 2. Maja – dzień pomiędzy dniami świątecznymi oficjalnymi ruchomymi – dzień roboczy lub wolny od pracy (niestandardowy);
- S07 – 3. Maja – Święto Konstytucji – Święto oficjalne nieruchome – dzień wolny od pracy;
- S08 – Zielone Świątki – Święto oficjalne ruchome – dzień wolny od pracy przypadający w niedzielę;
- S09 – Boże Ciało – Święto oficjalne ruchome – dzień wolny od pracy przypadający w czwartek;
- S10 – Wniebowzięcie Najświętszej Maryi Panny i Święto Wojska Polskiego – Święto oficjalne nieruchome – dzień wolny od pracy;
- S11 – Wszystkich Świętych – Święto oficjalne nieruchome – dzień wolny od pracy;
- S12 – Święto Niepodległości – Święto oficjalne nieruchome – dzień wolny od pracy;
- S13 – Wigilia Bożego Narodzenia – Święto oficjalne nieruchome – dzień roboczy;
- S14 – Boże Narodzenie (dzień 1.) – Święto oficjalne nieruchome – dzień wolny od pracy;
- S15 – Boże Narodzenie (dzień 2.) – Święto oficjalne nieruchome – dzień wolny od pracy;
- S16 – Sylwester – dzień poprzedzający Święto oficjalne nieruchome – dzień roboczy lub dzień wolny od pracy (niestandardowy);
- SE – Szwecja;
- SEE – System elektroenergetyczny;

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

SK2O	– Średnia krocząca dwuokresowa;
Skuteczność prognozy /prognozowania	– Dokładność określająca właściwości zbioru błędów otrzymanych w toku porównania wyników wykonanych procedur prognozy z rzeczywistymi realizacjami procesu [77]; Trafność prognozowania oznaczająca mniejszy dystans między prognozą a realizacją zmiennej prognozowanej [360];
sob.	– Sobota – dzień weekendu (bez uwzględnienia dni świątecznych i niestandardowych S01 – S16);
SSN	– Sztuczna sieć neuronowa;
SSN(F)	– Sztuczna sieć neuronowa falkowa
SVMZ	– Sztuczna sieć neuronowa (zespół sieci – metoda wektorów nośnych);
śr.	– Środa – dzień roboczy (bez uwzględnienia dni świątecznych i niestandardowych S01 – S16);
Św.	– Dni świąteczne i dni niestandardowe S01 – S16;
T_b	– Czas budowy modelu prognostycznego;
T_c	– Czas całkowity będący sumą czasu budowy modelu prognostycznego i kalibracji jego parametrów;
T_k	– Czas kalibracji parametrów modelu;
UW	– Uśrednianie Winsora;
Wig.	– dzień niestandardowy S16;
Winters – A 1	– Model Wintersa addytywny 1;
Winters – A 2	– Model Wintersa addytywny 2;
Winters – M 1	– Model Wintersa multiplikatywny 1;
Winters – M 2	– Model Wintersa multiplikatywny 2;
wt.	– Wtorek – dzień roboczy (bez uwzględnienia dni świątecznych i niestandardowych S01 – S16);
WW	– Wygładzanie wykładnicze.

Wykaz ważniejszych skrótów i pojęć w języku angielskim

Skrót	– Wyjaśnienie/Tłumaczenie
ACF	– <i>Autocorrelation Function;</i>
GA	– <i>Genetic Algorithm;</i>
ANFIS	– <i>Adaptive Neuro Fuzzy Inference System;</i>
APE	– <i>Absolute Percentage Error;</i>
AR	– <i>AutoRegressive;</i>
ARCH	– <i>Autoregressive Conditionally Heteroskedastic Model;</i>
ARIMA	– <i>Autoregressive Integrated Moving Average;</i>
ARMA	– <i>AutoRegressive Moving Average;</i>
BP	– <i>Back Propagation;</i>
C&RT	– <i>Classification And Regression Trees;</i>
CHAID	– <i>Chi – Square Automatic Interaction Detection;</i>
DEA	– <i>Data Envelopment Analysis;</i>
DOPH	– <i>Direct Optimum Parallel Hybrid;</i>
ECSTSP	– <i>Error – Correction State Space Model;</i>
EMLDE	– <i>Extreme Machine Learning (optimized by) Differential Evolution;</i>
EMLMDDE	– <i>Empirical Mode Decomposition – Differential Evolution – Extreme Machine Learning;</i>
EMLWTMABC	– <i>Ensemble Model Based on Machine Learning Methods and Data Preprocessing for Short – Term Electric Load Forecasting;</i>
ENTSO–E	– <i>European Network of Transmission System Operators for Electricity;</i>
<i>ex ante</i>	– Tryb oceny wyników prognoz przed ich rzeczywistym wykonaniem;
<i>ex post</i>	– Tryb oceny wyników prognoz po ich rzeczywistym wykonaniu;
FE	– <i>Fuzzy Estimators;</i>
FF	– <i>Fast Foreward;</i>
GIS	– <i>Geographic Information System;</i>
GPS	– <i>Global Positioning System;</i>
GRETLM	– <i>GRETLM (typ oprogramowania Open Source);</i>
IED	– <i>Intelligent Electronic Device;</i>
LPD	– <i>Linear Programming Dispatch;</i>
MA	– <i>Moving Average;</i>
MAPE	– <i>Mean Absolute Percentage Error;</i>
MARSplines	– <i>Multivariate Adaptive Regression Splines;</i>
MLP	– <i>MultiLayer Perceptron;</i>
MTR	– <i>Model Tree Rules;</i>
PACF	– <i>Partial Autocorrelation Function;</i>
PSO	– <i>Particle Swarm Optimization;</i>
PSO–SVM	– <i>Particle Swarm Optimization – Support Vector Machines;</i>
RBF	– <i>Radial Basis Function;</i>

RRBI	– <i>Fuzzy Interaction Regression for Short Term Load Forecasting;</i>
SARIMAX	– <i>Seasonal Autoregressive Integrated Moving Average Model with Exogenous Variables;</i>
SAS/ETS	– <i>SAS/Econometrics and Time Series Analysis (typ oprogramowania);</i>
SASVR	– <i>Seasonality – Adjusted, Support Vector Regression;</i>
SBS	– <i>Sequential Backward Selection Methods;</i>
SCADA	– <i>Supervisory Control and Data Acquisition;</i>
SDBWNN	– <i>Similar Day – Based Wavelet Neural Network;</i>
SFS	– <i>Sequential Forward Selection Methods;</i>
SIWNN	– <i>Similar Day – Based Wavelet Neural Network;</i>
SPSS	– <i>SPSS (typ oprogramowania);</i>
SSN–LSTM– RNN	– <i>Long Short Term Memory Networks for Short – Term Electric Load Forecasting;</i>
STSP	– <i>Modelowanie przestrzenne bez korekcji błędu State Space Model;</i>
SVM	– <i>Support Vector Machines;</i>
SVR	– <i>Supported Vector Regression;</i>
VMD	– <i>Variational Mode Decomposition;</i>
WAMS	– <i>Wide Area Management System;</i>
WTMABC	– <i>Wavelet Transform – Modified Artificial Bee Colony.</i>

Wykaz symboli

Symbol	– Wyjaśnienie
$(\mathbf{A})^{-1}$	– Macierz odwrotna;
a_n	– Parametr strukturalny w modelu autoregresji wyższego poziomu;
c_i	– Współczynnik autokowariancji;
r_i	– Współczynnik autokorelacji;
y_n	– Wartość zapotrzebowania na moc elektryczną w pojedynczej godzinie;
β_n	– Parametr strukturalny w modelu autoregresji pierwszego poziomu;
\mathbf{A}^T	– Macierz transponowana;
$SE(r)_{95\%}$	– Przedział ufności na poziomie 95%;
Y_n^P	– Prognoza zapotrzebowania na moc elektryczną w pojedynczej godzinie doby;
r_{xy}	– Korelacja dwóch zmiennych;
\bar{x}	– Wartość średnia;
y_{n-1}	– Wartość zapotrzebowania na moc elektryczną w pojedynczej godzinie doby modelu wykorzystującego metodę naiwną z opóźnieniem jednej doby;
y_{n-7}	– Wartość zapotrzebowania na moc elektryczną w pojedynczej godzinie doby modelu wykorzystującego metodę naiwną z opóźnieniem siedmiu dób;
ϕ_{21}	– Wartość autokorelacji cząstkowej dla rzędu pierwszego;
ϕ_{22}	– Wartość autokorelacji cząstkowej dla rzędu drugiego;
P	– Skuteczność prognozy w kontekście kryteriów dopuszczalności prognoz;
b	– Wektor;
<i>cov</i>	– Kowariancja;
<i>m</i>	– Wartość opóźnienia (przesunięcia);
<i>x</i>	– Cyfra lub liczba odzwierciedlająca numer opóźnienia występującego przed dobą <i>n</i> ;
<i>y</i>	– Cyfra lub liczba odzwierciedlająca liczbę dób kalendarzowych poprzedzających dobę <i>n</i> ;
<i>z</i>	– Cyfra lub liczba odzwierciedlająca liczbę dób poprzedzających dobę <i>n</i> ;
α	– Parametr wykładniczego w modelach Browna, Holta i Wintersa;
β	– Parametr wykładniczego w modelach Holta i Wintersa;
γ	– Parametr wykładniczego w modelu Wintersa.

Wprowadzenie

Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną w Krajowym Systemie Elektroenergetycznym (KSE), zwłaszcza w horyzoncie następnej doby, ma istotne znaczenie dla zapewnienia jego bezpiecznego funkcjonowania, a w konsekwencji dla ciągłości dostaw energii elektrycznej. Zmiany klimatyczne, technologiczne i społeczne, prowadzące do zmian zachowań odbiorców przemysłowych i gospodarstw domowych, w znaczący sposób wpływają na modyfikację dobowych profili obciążenia dużych systemów elektroenergetycznych. Do zmian klimatycznych zalicza się m.in. zwiększenie średniej temperatury otoczenia, zmniejszenie odczuwalnych różnic temperatury otoczenia pomiędzy porami roku oraz długie okresy upałów. Zmiany te wpływają na zwiększenie zapotrzebowania na moc elektryczną w okresach wysokich temperatur otoczenia, rosnące wykorzystanie urządzeń klimatyzacyjnych i innych urządzeń obniżających temperaturę i poprawiających jakość powietrza, a tym samym, powodują wzrost obciążenia systemu elektroenergetycznego, zwłaszcza w godzinach nocnych oraz w szczytach zapotrzebowania na moc i energię elektryczną. Dodatkowym skutkiem może być przenoszenie zapotrzebowania na moc elektryczną w obszar godzin nocnych przez odbiorców przemysłowych. Rosnący udział wytwarzania energii elektrycznej w źródłach fotowoltaicznych skutkuje zmniejszeniem dynamiki przyrostów zapotrzebowania na energię elektryczną w systemie elektroenergetycznym wobec rosnącego uniezależniania się części odbiorców energii elektrycznej, tzw. prosumentów, od dostaw energii elektrycznej z sieci [131], [326], [327]. Zmiany społeczne, w tym zwiększenie dobrobytu społecznego, czy okresy jego zmniejszenia, wpływają na okresowe przyrosty lub spadki zapotrzebowania na energię elektryczną.

Czynnikiem, którego ryzyko materializacji systematycznie rośnie, jest możliwość zakłócenia ciągłości komunikacji elektronicznej, która jest głównym środkiem zapewniania danych wejściowych do opracowywania prognoz zapotrzebowania na moc elektryczną w systemie elektroenergetycznym. Danymi wejściowymi do modeli prognozowania zapotrzebowania na moc elektryczną są zazwyczaj prognozy i dane historyczne dotyczące parametrów pogodowych oraz prognozy i dane historyczne dotyczące generacji w źródłach wiatrowych i fotowoltaicznych. Wpływają one bezpośrednio na zmiany w kształtowaniu profili obciążeń dobowych systemów elektroenergetycznych. W obliczu tych zmian i ryzyka zakłóceń w dostępie do aktualnych prognoz danych wejściowych do modeli prognostycznych, kluczowe jest posiadanie przez operatorów systemów elektroenergetycznych skutecznych metod i modeli prognostycznych pozwalających na uniezależnienie ich od dostępu do prognoz parametrów wejściowych do stosowanych obecnie modeli prognostycznych. Ponowne ukierunkowanie uwagi na metody autoregresyjne, które w procesie prognozowania nie wykorzystują innych danych niż te o własnych wartościach historycznych, stanowi jedno z wyzwań, w szczególności w obliczu bardzo wysokiej skuteczności zaawansowanych metod (wartość błędu MAPE < 1,00%) stosowanych w stabilnych warunkach rozwoju gospodarki krajowej i tym samym stabilnego i systematycznego wzrostu zapotrzebowania na energię elektryczną.

Opracowanie metody prognostycznej autoregresyjnej o wskazanej efektywności stanowi duże wyzwanie badawcze. Istotnym czynnikiem nie jest w tym przypadku czasochłonność opracowywania samych prognoz, lecz czasochłonność opracowania takiej metody i jej pozytywnego zweryfikowania pod względem zadanego prognozu dopuszczalności oraz jakości wpływającej na dopuszczalność prognoz i uwzględniania w procesie planowania krajowego bilansu mocy z wyprzedzeniem jednej doby. Osiągnięcie wysokiej skuteczności prognoz opracowywanych za pomocą metod autoregresyjnych ma kluczowe znaczenie w kwestii reakcji na dynamiczne i nietypowe zmiany profili zapotrzebowania na moc elektryczną, które nie mają odniesień historycznych oraz w kontekście zakłóceń bezpieczeństwa cyfrowego w kraju lub w sieci teleinformatycznej operatora systemu przesyłowego.

Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną w KSE jest procesem stochastycznym, cechującym się znaczącą zmiennością, uzależnionym od pory dnia i roku. Profil zapotrzebowania na moc elektryczną dzieli się zazwyczaj na jeden lub dwa szczyty obciążenia przypadające w okresie letnim (szczyt popołudniowy i wieczorny) oraz jeden szczyt obciążenia w okresie zimowym (szczyt popołudniowy). Ze względu na nierównomierność zapotrzebowania, w ciągu poszczególnych momentów doby, kluczowe jest jak najdokładniejsze prognozowanie wartości zapotrzebowania na moc elektryczną. Dla Operatora Systemu Przesyłowego (OSP), w horyzoncie krótkoterminowym, szczególnie istotne jest wyznaczenie ekstremów poboru mocy, zarówno w szczycie, jak i dolinie zapotrzebowania. Poszukiwanie nowych rozwiązań z dziedziny prognozowania [171] funkcjonowania sieci przesyłowej w aspekcie rozwoju metod i narzędzi ma kluczowe znaczenie dla utrzymania bezpieczeństwa funkcjonowania KSE [328], [329]. Istotne w tym kontekście są główne wyzwania przed którymi stoi OSP, do których należą: (i) trend zwiększania zapotrzebowania na moc elektryczną, (ii) wzrost udziału odnawialnych źródeł energii, takich jak źródła wiatrowe i fotowoltaiczne, (iii) elastyczność poboru realizowana przez stronę odbiorczą, (iv) zmiany technologiczne związane z popularyzacją i upowszechnianiem stosowania urządzeń elektrycznych oraz (v) ograniczanie ponoszenia kosztów systemowych związanych ze stratami energii elektrycznej [124], [316], [315]. Dodatkowymi czynnikami wpływającymi na wielkość zapotrzebowania na moc elektryczną w KSE są również: rozwój technologii wytwarzania i magazynowania energii, nowe technologie prosumenckie oraz elektromobilność [188]. Aspekty te potwierdzają zasadność zapewnienia stosownego reagowania na zmianę kształtu poboru energii oraz prognozowanie zapotrzebowania na moc elektryczną z zapewnieniem jak największej jego skuteczności [160].

W polskim systemie elektroenergetycznym, szczególnie w ostatnich latach drugiej dekady dwudziestego pierwszego wieku, obserwowane jest zjawisko wyrównywania dysproporcji między poziomem zapotrzebowania na moc elektryczną w godzinach szczytowego zużycia oraz w godzinach doliny nocnej. Wynika to między innymi z dostępności nowoczesnych technologii i zmiany nawyków odbiorców, w tym zachowań odbiorców przemysłowych oraz gospodarstw domowych. Ponadto, czynnikiem wpływającym na zmiany profilu zapotrzebowania na moc elektryczną w Polsce

są zmiany podstawowych parametrów opisujących warunki pogodowe. Powiązanie zmian technologicznych, zachowań odbiorców oraz zmian klimatycznych skutkuje koniecznością opracowywania nowych metod badawczych. Metody te powinny wspomagać prognozowanie zmian kształtu profilu obciążenia KSE, a wynikające z nich prognozy powinny stanowić jeden z najważniejszych parametrów składowych planów pracy KSE.

Z punktu widzenia kosztów funkcjonowania systemu elektroenergetycznego korzystniejsze dla Operatora Systemu Przesyłowego jest opracowywanie prognoz zapotrzebowania na moc i energię elektryczną o wartościach wyższych niż wykonanie (przeszacowanie), a nie niższych od wykonania (niedoszacowanie). Wynika to z faktu, że w przypadku niedoszacowania dochodzi do konieczności korzystania z droższych ofert przyrostowych zakupu mocy elektrycznej. W godzinach nocnych, gdy ceny w oferowanych pasmach (zwanych również przyrostowymi i redukcyjnymi) są niższe niż w szczycie porannym i wieczornym, w KSE często dochodzi do niedoszacowania prognoz zapotrzebowania na moc elektryczną, co zachodzi rzadziej dla pozostałych godzin doby (a w szczególności dla szczytów [69], [215], [184], [264]). W związku z powyższym dostrzeżony został problem badawczy związany z potencjałem tkwiącym w możliwości zwiększenia dokładności prognoz zapotrzebowania na moc elektryczną w godzinach nocnych, dla potrzeb tworzenia planów koordynacyjnych dobowych [259].

Rozprawa wpisuje się w dynamiczne zmiany technologiczne wynikające z uwarunkowań legislacyjnych związanych z zapewnieniem bezpieczeństwa cybernetycznego. Szczególna uwaga w ostatnich latach, zarówno w obszarze rozważań teoretycznych, jak i praktycznych, poświęcana jest opracowywaniu metod i modeli prognostycznych odpornych na zakłócenia w dostawach danych od dostawców zewnętrznych, w tym dedykowanych prognoz parametrów pracy systemów elektroenergetycznych, jak i prognoz i pomiarów parametrów meteorologicznych. Zakłócenia dostaw danych wykorzystywanych jako zmienne wejściowe do modeli prognostycznych mogą wynikać z naruszenia ciągłości pracy systemów teleinformatycznych natury technologicznej, jak i ataków cybernetycznych. Zapewnienie bezpiecznej pracy systemu elektroenergetycznego wymaga utrzymania ciągłości procesów prognostycznych charakteryzujących się łagodną regresją trafności opracowywanych prognoz. Zagadnienie wyposażenia operatorów w odpowiednie narzędzia niezależne od dostaw danych zewnętrznych ma istotne znaczenie dla operatorów systemów przesyłowych. Nowoczesne autoregresyjne metody i modele prognostyczne wpisują się w zidentyfikowane trendy rozwojowe i stanowią narzędzie odpowiadające na wskazane praktyczne potrzeby operatorów systemów przesyłowych. W świetle przedstawionych uwarunkowań i przesłanek, **przedmiotem rozprawy** jest krótkoterminowe prognozowanie zapotrzebowania na moc elektryczną w Krajowym Systemie Elektroenergetycznym dla każdej godziny doby, ze szczególnym uwzględnieniem pierwszych sześciu godzin doby.

Głównym celem pracy jest opracowanie autoregresyjnej metody do prognozowania zapotrzebowania na moc elektryczną, cechującą się co najmniej dopuszczalną jakością prognoz (tj. wartościami błędu $4,00\% < MAPE \leq 6,00\%$), ze szczególnym uwzględnieniem pierwszych sześciu godzin doby oraz dla dni świątecznych i niestandardowych. Zadania nałożone na Polskie Sieci Elektroenergetyczne S.A. (PSE S.A.), wynikające z Ustawy Prawo Energetyczne, mają oprócz skutecznych działań dotyczących wymaganej jakości i bezpieczeństwa dostaw energii elektrycznej, zapewniać również działania zapewniające ekonomicznie uzasadnione funkcjonowanie KSE. Jest to realizowane m.in. poprzez minimalizowanie błędów prognoz, w tym prognoz zapotrzebowania na moc elektryczną. Pierwsze sześć godzin doby charakteryzuje się niższymi cenami mocy elektrycznej na rynku bilansującym i na Towarowej Giełdzie Energii w porównaniu do pozostałych godzin doby, a w szczególności do godzin, w których występują szczyty zapotrzebowania na moc elektryczną. Wartości błędów prognoz zapotrzebowania na moc elektryczną zidentyfikowane w rozprawie wskazują, że dla pierwszych sześciu godzin doby są one większe niż dla pozostałych godzin. Tym samym zidentyfikowano obszar badawczy posiadający aspekt praktyczny, dla którego możliwe jest opracowanie metody prognozowania zapewniającej skuteczność konkurencyjną, dla pierwszych sześciu godzin doby. Poprawa efektywności prognozowania w pierwszych sześciu godzinach doby może również wspomagać, w kontekście modyfikacji prognozy wielkości zapotrzebowania na moc elektryczną, współpracę sieci przesyłowej ze źródłami wiatrowymi (posiadającymi naturę stochastyczną [204]). Jest to uzasadnione tym, że w godzinach nocnych, w których w okresach niskiego zapotrzebowania, w szczególności występujących w dni świąteczne, może dochodzić do nadgeneracji mocy elektrycznej i tym samym do wystąpienia ryzyka konieczności redukcji generacji w tych źródłach.

Cele cząstkowe warunkujące osiągnięcie głównego celu pracy zostały sformułowane w sposób następujący:

1. Identyfikacja dynamicznych zmian zapotrzebowania na moc elektryczną w Krajowym Systemie Elektroenergetycznym dla potrzeb opracowania nowej autoregresyjnej metody prognozowania.
2. Opracowanie nowej elastycznej metody prognozowania zapotrzebowania na moc elektryczną w Krajowym Systemie Elektroenergetycznym, wykorzystującej ważne współczynniki funkcji autokorelacji cząstkowej, możliwej do zastosowania również w zagranicznych systemach elektroenergetycznych.
3. Opracowanie i ocena prognoz *ex post* zapotrzebowania na moc elektryczną w Krajowym Systemie Elektroenergetycznym dla każdej godziny doby, w podziale na pierwsze sześć i pozostałych osiemnaście godzin oraz w podziale na dni świąteczne i niestandardowe.
4. Opracowanie i ocena prognoz *ex post* zapotrzebowania na moc elektryczną w wybranych zagranicznych systemach elektroenergetycznych oraz na tle wybranych autoregresyjnych metod prognozowania dla każdej godziny doby, w podziale na pierwsze sześć i pozostałych osiemnaście godzin oraz w podziale na dni świąteczne i niestandardowe.

W nawiązaniu do celów pracy oraz mając na uwadze przedmiot badań, sformułowano następujące **hipotezy badawcze**:

- I. Możliwe jest opracowanie nowej elastycznej metody prognozowania zapotrzebowania na moc elektryczną w Krajowym Systemie Elektroenergetycznym, cechującej się współmiernością i racjonalnością nakładów, względem oczekiwanego poziomu jakości prognoz.
- II. Celowe i możliwe jest opracowanie modelu prognostycznego bazującego na ważonych współczynnikach funkcji autokorelacji cząstkowej, dedykowanego pierwszym sześciu godzinom doby oraz wybranym dniom świątecznym i niestandardowym, dla dużych systemów elektroenergetycznych.
- III. Możliwe jest uzyskanie dopuszczalności i skuteczności prognoz na poziomie konkurencyjnym względem metod obecnie stosowanych przez operatorów systemów przesyłowych dla pierwszych sześciu godzin doby oraz dla dni świątecznych i niestandardowych.

Weryfikacja hipotez badawczych oraz realizacja sformułowanych celów pracy jest możliwa dzięki zastosowaniu opracowanej **metodyki badawczej**, która opiera się na ważeniu współczynników funkcji autokorelacji cząstkowej oraz wykorzystaniu równań Yule – Walker'a. Przyjęto, że opracowana zostanie intuicyjna i szybka metoda do wykonywania krótkoterminowych prognoz obciążenia KSE, umożliwiająca uniezależnienie się od zewnętrznych danych, bez jednoczesnej znaczącej regresji skuteczności. Określono kryteria dopuszczalności prognoz, które zawężono względem doniesień literaturowych. Opracowano również kryteria oceny efektywności prognoz oraz określono trzy obszary walidacyjne umożliwiające zweryfikowanie opracowanej metody prognozowania zapotrzebowania na moc elektryczną w KSE. Badania obejmują trzy główne obszary walidacyjne:

- Symulacje prognostyczne dla Krajowego Systemu Elektroenergetycznego oraz porównanie ze skutecznością prognoz osiąganą dla KSE.
- Symulacje prognostyczne dla dwóch wybranych zagranicznych systemów elektroenergetycznych przesyłowych (Szwecji i Francji) oraz porównanie z efektywnością prognoz osiąganą dla tych systemów.
- Symulacje prognostyczne dla osiemdziesięciu modeli ośmiu grup wybranych metod prognozowania z wykorzystaniem danych i prognoz historycznych dla KSE oraz porównanie z jakością prognoz osiągniętych z wykorzystaniem opracowanej metody.

Przmiotowi pracy, sformułowanym celom i hipotezom badawczym, podporządkowano **układ rozprawy**, który obejmuje wprowadzenie, cztery rozdziały oraz podsumowanie i wnioski końcowe. Rozdział pierwszy umiejscawia badane zagadnienie w kontekście energetyki, elektroenergetyki, ekonometrii i statystyki. Odniesienia do energetyki i elektroenergetyki dotyczą zapotrzebowania na moc elektryczną i związanego z nią obciążenia systemu elektroenergetycznego wraz z jego zmianami w czasie. W rozdziale drugim zaprezentowano stan badań w przedmiotowym obszarze na podstawie analizy literatury krajowej i zagranicznej. Kryterium kwalifikującym daną pozycję do szczegółowej analizy było wskazanie w publikacjach wykorzystania błędu MAPE (ang. *Mean Absolute Percentage Error*). Zastosowane kryterium pozwoliło

na wyodrębnienie szczegółowego zbioru zgromadzonych publikacji. Rozdział trzeci poświęcony jest opracowaniu modelu matematycznego wykorzystującego metodę ważonych współczynników funkcji autokorelacji cząstkowej. Dodatkowym wkładem rozprawy do stanu wiedzy [261], [325] w zakresie współczynników funkcji autokorelacji cząstkowych dla szeregów czasowych jest opracowanie strategii ważenia uzyskanych wartości współczynników w celu weryfikacji skuteczności opracowanego podejścia na przykładzie prognoz z wyprzedzeniem jednej doby dla systemów elektroenergetycznych. Rozdział czwarty poświęcono przedstawieniu kryteriów oceny efektywności prognoz, krytycznej analizie uzyskanej skuteczności prognozowania za pomocą opracowanej metody prognozowania, przedstawiono analizę podsumowującą przeprowadzonych badań symulacyjnych w porównaniu do wyników uzyskanych dla zagranicznych systemów elektroenergetycznych Szwecji i Francji, opracowano analizę jakości opracowanej metody na tle osiemdziesięciu modeli podstawowych metod autoregresyjnych oraz przedstawiono podsumowanie dla trzech obszarów walidacyjnych. W ostatniej części pracy zawarto podsumowanie rozprawy i wnioski końcowe.

1. Tło problematyki prognozowania zapotrzebowania na moc elektryczną

1.1. Prognozowanie w kontekście ekonometrii

Prognozowanie jest procesem przewidywania i oceny przyszłych zdarzeń, a jej efektem jest prognoza, będąca terminem wprowadzonym do nauki przez Hipokratesa. Termin ten łączy greckie słowo *gnoza*, określające wiedzę oraz słowo *pro* odnoszące się do uprzedniości i przewidywania [217]. Wykonanie prognozy na podstawie dotychczasowego przebiegu analizowanego zjawiska i jego aktualnego stanu umożliwia dokonanie wyboru jego najbardziej prawdopodobnego rozwoju [355], [371]. Istnieje wiele definicji słowa prognoza, a samo słowo jest wieloznaczne i może odnosić się do warunkowości, bezwarunkowości czy uzależnienia realizacji prognozy od zaistnienia pewnych okoliczności. Inne definicje prognozy lub samego procesu prognozowania opisują powyższe jako: sąd, w którym czas nie odgrywa znaczącej roli [369], [70]; sąd, którego prawdziwość jest zdarzeniem losowym, przy czym prawdopodobieństwo zdarzenia jest nie mniejsze od ustalonej z góry, bliskiej jedności liczby zwanej wiarygodnością prognozy [140], [226]; wnioskowanie o rzeczach niedostępnych bezpośredniemu poznaniu [284]; konkretny wynik wnioskowania w przyszłość na podstawie znajomości modelu ekonometrycznego [139], [217], [313], [260], [111], [176] opisującego pewien wycinek sfer zjawisk ekonomicznych [247]. Kolejną definicją jest również predykcja (ekonometryczna) określana jako ogół zasad i metod wnioskowania o przyszłości na podstawie odpowiedniego modelu ekonometrycznego, natomiast konkretnym wynikiem tego procesu wnioskowania jest prognoza [246]. W rozprawie prognozę rozumie się zgodnie z tą definicją.

Analizy wykorzystujące podejście ekonometryczne w prognozowaniu stosują narzędzia statystyczne w odniesieniu do danych ekonomicznych, gdzie pierwszym zadaniem jest sformułowanie relacji ekonomicznej, która jest, z konieczności, uproszczonym modelem rzeczywistego procesu [217], [344], [142]. Dwoma następnymi głównymi zadaniami ekonometrii (poza ekonomią matematyczną, której domeną są wyłącznie zastosowania matematyki [217]): są estymacja i weryfikacja tak sformułowanych modeli oraz ich zastosowanie w prognozowaniu i analizach symulacyjnych [217]. Prognozowanie często zastępowane jest określeniem predykcja, wnioskowaniem w przyszłość i stanowi swoisty sąd o przyszłości, natomiast ocena przeszłych zdarzeń lub stanu aktualnego jest oszacowaniem lub prognozą *ex post*.

Proces prognozowania opiera się m.in. na rozważaniach teoretycznych, rozważaniach analitycznych, rozważaniach logicznych i wglądzie w doświadczenia płynące z kształtowania się analizowanego zjawiska. Zgrubny podział metod prognozowania rozpoczyna się od podziału na metody matematyczne i niematematyczne [369], [371]. Metody matematyczne, a właściwie matematyczno – statystyczne, wykorzystują modele deterministyczne i ekonometryczne. Metody niematematyczne, zwane heurystycznymi, bazują na doświadczeniu i wiedzy ekspertów wykorzystując m.in. metody ankietowe, intuicyjne, kolejnych przybliżeń, ekspertyz, metodę delficką, metody refleksji, metody

analogowe (z wykorzystaniem analogii) [371]. Analogie biologiczne, historyczne i przestrzenno – czasowe stosowane są do budowania prognoz jakościowych, natomiast analogie historyczne i przestrzenno – czasowe służą do budowania prognoz obu rodzajów.

Metody wykorzystujące modele ekonometryczne uwzględniają nurt opierający się na modelach jednorównaniowych i wielorównaniowych. Do modeli jednorównaniowych zalicza się klasyczne modele trendu, adaptacyjne modele trendu, modele przyczynowo – opisowe, modele autoregresyjne [282], natomiast do modeli wielorównaniowych zalicza się modele proste, rekurencyjne i modele o równaniach współzależnych [371], [297]. Rozprawa doktorska wykorzystuje prognozowanie w oparciu o metody matematyczno – statystyczne i modele ekonometryczne autoregresyjne jednorównaniowe.

Prognozy opracowane w rozprawie dotyczą horyzontu następnej doby i w zależności od klasyfikacji spotykanej w doniesieniach literaturowych mogą być określane jako bezpośrednie [371], [298], czyli bezzwłoczne, które nie przekraczają jednego miesiąca lub mogą być określane jako krótkoterminowe o horyzoncie poniżej trzech miesięcy lub jako operacyjne czyli takie, które są wykorzystywane w bieżącej działalności [371], [299]. W odniesieniu do zapotrzebowania na moc elektryczną i z uwzględnieniem interpretacji zamieszczonej w [371], [370], prace symulacje prognostyczne opracowane w rozprawie są prognozami krótkoterminowymi operacyjnymi. Obecną tendencją wynikającą z rozwoju technik informatycznych i rozwoju rynków energii jest opracowywanie prognoz dla potrzeb planów pracy systemów elektroenergetycznych w horyzoncie krótszym od jednej godziny, czyli najczęściej 15 minut i 5 minut, co stanowi wyzwanie wobec obowiązującego obecnie rynku dobowo – godzinowego.

Zastosowanie narzędzi statystycznych w analizie danych ekonomicznych w sposób naturalny łączy się z zagadnieniem prognozowania w energetyce i elektroenergetyce. Powiązanie konieczności i zasadności wykorzystania prognozowania w tych dziedzinach z zagadnieniami ekonometrii wynika wprost z jednego z głównych obowiązków nałożonego na każdego z OSP jakim jest zarządzanie majątkiem sieciowym oraz zapewnieniem ciągłości dostaw energii elektrycznej do odbiorców z uwzględnieniem minimalizacji kosztów funkcjonowania całego systemu elektroenergetycznego. Tym samym rozważania zawarte w rozprawie w sposób oczywisty wymuszają zastosowanie metod ekonometrycznych w dziedzinie prognozowania funkcjonowania systemu.

W tym kontekście niezbędne jest wskazanie elementów [217], które stanowią opis przeprowadzonych poszukiwań unikatowego podejścia w dziedzinie prognozowania w odniesieniu do predykcji zapotrzebowania na moc elektryczną. Do elementów tych zalicza się [217]:

- 1) podstawy statystyki i algebry macierzy;
- 2) regresję prostą;
- 3) regresję wieloraką;
- 4) heteroskedastyczność;
- 5) autokorelacje;

- 6) współliniowość;
- 7) zmienne jakościowe i zmienne ucięte;
- 8) modele wielorównaniowe;
- 9) modele nieliniowe i modele oczekiwania;
- 10) błędy w zmiennych;
- 11) diagnostykę, wybór modelu i testowanie specyfikacji;
- 12) analizę szeregów czasowych;
- 13) autoregresję wektorową, pierwiastki jednostkowe i kointegrację;
- 14) analizę danych panelowych;
- 15) teorię dużych prób;
- 16) metody próbkowania w małej próbie.

Pierwszym elementem składowym są podstawy statystyki i algebry macierzy, na które składają się prawdopodobieństwo, zmienne losowe i rozkłady prawdopodobieństwa, rozkład normalny i związane z nim rozkłady, klasyczne wnioskowanie statystyczne i własności estymatorów [217]. Ten element w odniesieniu do badanego zagadnienia implikuje, że analiza rozkładu normalnego wskazuje na jego znaczącą asymetrię. Dlatego zastosowanie klasycznych metod prognozowania może nie stanowić poprawy jakości prognozowania, stąd też niezbędne jest poszukiwanie metody niwelującej wnioski wynikające z analizy rozkładu analizowanej zmiennej.

Drugim elementem składowym jest regresja prosta [217]. Na element ten składają się metoda najmniejszych kwadratów, wnioskowanie statystyczne, analiza wariancji, predykcja wartości oczekiwanej, analiza obserwacji nietypowych oraz losowość zmiennych objaśniających. W regresji, w nawiązaniu do badanego zagadnienia, często dochodzi do „pułapki regresji” czyli regresu do średniej. Jest to tzw. Fenomen Galtona, który wskazuje, że przy uwzględnieniu zmiennej objaśniającej o naturze losowej dochodzi do obniżenia jakości opracowywanych prognoz. Pułapka ta prowadzi do konieczności oceny możliwości zastosowania kolejnego elementu dziedziny ekonometrii, którym jest regresja wieloraka, która pozwala na uwzględnienie w modelu prognostycznym więcej niż jednej zmiennej objaśniającej [145]. Wzbogaceniem metody regresji prostej [257] jest zastosowanie współczynnika korelacji wielorakiej, analizy wpływu poszczególnych zmiennych objaśniających, testów stabilności oraz zapisu macierzowego dla modelu regresji wielorakiej.

Zagadnienie regresji wielorakiej, będące **trzecim elementem składowym** ekonometrii [217] prowadzi do tematyki optymalnego doboru zmiennych objaśniających, które w swojej złożoności, stanowi odrębne zagadnienie ekonometryczne. Przeprowadzone badania literaturowe wskazują, że poszukiwania optymalnego zestawu takich zmiennych nie zawsze pozwalają na uzyskanie korzystniejszej jakości prognozowania w porównaniu do metod naiwnych, czy też klasycznej regresji. W związku z powyższym poszukiwania nowej metody prognozowania zapotrzebowania na moc elektryczną ukierunkowano na dalsze poszukiwania elementów ekonometrii, które mogą poprawić jakość opracowywanych prognoz.

Czwartym elementem składowym nauki ekonometrii jest heteroskedastyczność, jej konsekwencje i wynikająca z niej ocena wariancji estymatora metody najmniejszych kwadratów w przypadku heteroskedastyczności [217]. Zagadnienia regresyjne zakładają homoskedastyczność składników losowych, czyli mających stałą wariancję. Przebiegi zapotrzebowania na moc elektryczną w KSE nie posiadają takich właściwości, w szczególności w odniesieniu do poszczególnych godzin doby, dlatego też są heteroskedastyczne. Ich reszty są większe co do wartości bezwzględnej dla większych wartości obserwacji, czyli wariancje składników losowanych nie są stałe i rosną wraz ze wzrostem wartości obserwowanego szeregu [217], [297], [298], [299], [294]. Jednym z powszechnie wykorzystywanych narzędzi oceny heteroskedastyczności obserwowanej zmiennej jest kwadrat Anscombe'a. Inne testy to test Goldfelda – Quandta, test Breuscha – Pagana. Zastosowanie modelu wykorzystującego heteroskedastyczne składniki losowe skutkuje niedoszacowaniem wariancji estymatora metody najmniejszych kwadratów i skróceniem długości przedziałów ufności, co wpływa również na weryfikację hipotez statystycznych. Tym samym estymator metody najmniejszych kwadratów jest nieciążony i nieefektywny, a estymatory średnich błędów szacunku są obciążone. Zjawisko to jest szczególnie widoczne w prognozowaniu zapotrzebowania na moc elektryczną w KSE szczególnie w godzinach nocnych (ale również w godzinach popołudniowych), w czasie których dochodzi do niedoszacowania prognoz zapotrzebowania.

Mając na uwadze powyższe, rozprawa została ukierunkowana na poszukiwania metody, która pozwoli na minimalizację uzyskiwanych niedoszacowań w godzinach nocnych.

Piątym elementem składowym są autokorelacje [217]. Autokorelacje w naturalny sposób występują w szeregu zapotrzebowania na moc elektryczną w KSE. Autokorelacje dotyczą m.in. typów dni tygodnia, miesięcy i kwartałów, tym samym umożliwiając analizy dotyczące sezonowości i okresowości. Zapotrzebowanie na moc elektryczną w Krajowym Systemie Elektroenergetycznym, będące szeregiem czasowym jest wypadkową wielu składników losowych, z którymi analizowany szereg jest skorelowany. Korelacja składników losowych jest często wynikiem wzajemnego powiązania pominiętych zmiennych objaśniających, które są reprezentowane właśnie przez składniki losowe [217], [287], [297], [298], [299], [266]. Jak wspomniano wcześniej, optymalny dobór zmiennych objaśniających, czyli zmiennych losowych wpływających na analizowane zjawisko, jest zagadnieniem złożonym i może skutkować niezadowolającymi wynikami. W nawiązaniu do powyższego, badania w rozprawie ukierunkowano na poszukiwania takiego wykorzystania zjawiska autokorelacji, aby uzyskać niezależność od zmiennych zewnętrznych objaśniających analizowane zjawisko.

Szósty element składowy to współliniowość [217]. Zagadnienie współliniowości jest jednym z najtrudniejszych problemów w obszarze tematycznym regresji wielorakiej [217], [297], [298], [299]. Zagadnienie regresji wielorakiej stosuje analizę wpływu na objaśnianie zjawisko i wzajemnych powiązań pomiędzy parametrami, które je opisują. Wraz ze wzrostem błędów oszacowania wartości parametrów objaśniających analizowane zjawisko dochodzić może do wzrostu wartości błędów szacunku samego

zjawiska. Wraz ze wzrostem liczby analizowanych zmiennych objaśniających, przy braku dodatkowej informacji o (co najmniej) przedziale błędu oszacowania, rośnie ryzyko większej liczby błędów oszacowania zmiennej szacowanej, będącej wielkością prognozowaną. Zwiększenie liczby parametrów objaśniających wpływa nie tylko na koszty pozyskania wartości tych parametrów, koszty ich przystosowania do analiz prognostycznych, ale także, w sposób jednoznaczny, zwiększa stopień skomplikowania modeli prognostycznych i czas przeznaczony na ich opracowanie, utrzymanie w stanie aktualności oraz sam proces prognozowania. Istnieje wiele koncepcji współliniowości i miar ich oceny [120], które mogą być bezużyteczne i mylące [217], [297], [299], ponieważ uzależnione są od struktury korelacyjnej zmiennych objaśniających [299]. Przykładowo w analizach predykcyjnych istotnych parametrów pracy KSE, tj. zapotrzebowania na moc elektryczną, wielkość strat przesyłowych [43], [57], [58], czy zwiększania liczby zmiennych objaśniających, w sposób jednoznaczny mogą wpływać na wzrost otrzymywanych błędów prognoz do poziomu przekraczającego jakość prognoz osiągniętych dowolnymi metodami naiwnymi. Do metod służących do usuwania z zagadnienia prognostycznego problemu współliniowości zalicza się regresję grzbietową, regresję względem głównych składowych czy usuwanie zmiennych [217], [297], w szczególności zmiennych skorelowanych pomiędzy sobą w wysokim stopniu. Zagadnienie doboru zmiennych objaśniających jest zagadnieniem złożonym [63], [64], [65] i czasochłonnym [44], [49], [52], [59], które stanowić może osobną dziedzinę analiz statystyczno – prognostycznych. Jednym ze skutecznych środków zaradczych dla zjawiska współliniowości jest wydłużanie szeregu czasowego analizowanych danych historycznych o badanym zjawisku [217], [298]. Alternatywnym środkiem zaradczym jest zagadnienie sprawdzania zgodności modelu procesu z danymi wytworzonymi w wyniku jego wykonania w przypadkach, gdy dane nie są podawane jako dziennik zdarzeń, ale jako zbiór szeregów czasowych zawierających ewolucję zmiennych zaangażowanych w proces [270], [318]. Dzięki zastosowaniu bardzo długiego szeregu czasowego (10 lat kalendarzowych) możliwe jest pełne przeanalizowanie skuteczności opracowanej metody, z jednoczesnym odcięciem od zagadnień związanych ze współliniowością zmiennych objaśniających.

Siódmy element składowy to zmienne jakościowe i zmienne ucięte [217]. Zmienne jakościowe (ang. *Dummy Variables*) zwykle odnoszą się do zmiennych binarnych, przedstawianych za pomocą zer i jedynek. Zmienne tego typu nazywane są również zmiennymi dwumianowymi i dychotomicznymi. Zmienne jakościowe binarne w zagadnieniach ekonometrycznych, tym samym prognostycznych, tworzone są również w sposób sztuczny. Przykładowo pojedyncza godzina doby jest kodowana (tworzona sztucznie) w szeregu czasowym. Zmienne jakościowe, najczęściej wynikające z badań ankietowych, funkcjonują m.in. w naukach medycznych i społecznych [195]. W zagadnieniu prognozowania parametrów opisujących funkcjonowanie systemów elektroenergetycznych zmienne jakościowe binarne są powszechnie stosowane, w modelach wykorzystujących zagadnienie regresji wielorakiej, ze względu na wzmocnienie zależności korelacyjnych w odniesieniu do parametru prognozowanego. Przebiegi szeregów czasowych są złożeniem wartości mierzalnych (wartość

zapotrzebowania na moc elektryczną w normalnym stanie pracy zawsze jest większa od zera) dlatego też nie stosuje się do ich analizy liniowych modeli prawdopodobieństwa, modeli logitowych i probitowych. Zmienne ucięte stosowane są w analizach z wykorzystaniem modeli normalnej regresji cenzurowanej (tobitowych) i modeli regresji uciętej. Zmienne jakościowe (głównie sztuczne) jako zmienne objaśniające w modelach regresji stosowane są do [217], [300]: (i) ujęcia różnic między wartościami wyrazów wolnych, (ii) ujęcia różnic między wartościami współczynników kierunkowych przy zmiennych objaśniających, (iii) estymacji modeli z ograniczeniami dotyczącymi parametrów w różnych równaniach, (iv) testowania stabilności parametrów regresji. Modele regresji uciętej stosowane są dla danych, które dobierane są w sposób losowy, a wylosowane wartości są kwalifikowane do ostatecznej postaci szeregu czasowego, po uwzględnieniu progu ucięcia (dane pochodzą z rozkładu uciętego). W przypadku modeli regresji tego typu stosuje się metodę największej wiarygodności zamiast metody najmniejszych kwadratów. Poszukiwania optymalnego doboru zmiennych objaśniających jakościowych tworzonych sztucznie wskazują, że w odniesieniu do prognozowania zapotrzebowania na moc elektryczną uzyskuje się znaczącą poprawę jakości prognozowania z wykorzystaniem metody *MARSplines* (krzywych sklepanych) [52, [56], [51].

Ósmy element składowy to modele wielorównaniowe [217]. W sytuacji gdy kilka zmiennych objaśniających (niezależnych) jest silnie skorelowanych, możliwe jest złagodzenie jednego z podstawowych założeń klasycznej metody regresji, które mówi o braku korelacji tych zmiennych. Złagodzenie tego założenia pozwala na zastosowanie modeli wielorównaniowych, w których zmienne współzależne poddają się estymacji, a następnie identyfikacji [217]. W równaniach wielorównaniowych stosuje się też pośrednie metody najmniejszych kwadratów. Jednym z zagadnień ekonometrycznych, w którym zmienne objaśniające są niezależne od składnika losowego jest zagadnienie popytu i podaży. Dodatkowym czynnikiem wpływającym na jakość prognozowania może być pomiar zmiennych objaśniających z błędami. Zmienne występujące w modelach wielorównaniowych można podzielić na endogeniczne i egzogeniczne. Zmienne endogeniczne są zmiennymi łącznie współzależnymi lub wspólnie ustalonymi (objaśnianymi oddzielnie w pojedynczych równaniach), natomiast zmienne egzogeniczne (w ramach jednej z wielu definicji) są zmiennymi z góry ustalonymi (niezależnymi od składnika losowego) [217] – podejście Fundacji Cowlesa poddawane krytyce m.in. przez Krytykę Liu [201] i Krytykę Lucasa [205]. Modele wielorównaniowe poddawane są procesowi identyfikacji przez postać zredukowaną w celu oszacowania parametrów strukturalnych lub alternatywnie sprawdzeniu możliwości przedstawienia pojedynczego równania jako kombinacji liniowej innych równań układu [217]. W drugim kroku modele tego typu są poddawane estymacji za pomocą metod zmiennych instrumentalnych, tj. estymacji z ograniczoną informacją (estymacja pojedyncza) i estymacji z pełną informacją (estymacja systemowa) lub za pomocą podwójnej metody najmniejszych kwadratów, gdzie analizowane zmienne traktuje się jako zmienne objaśniające, a nie jako instrumenty. Alternatywną i jednocześnie pierwszą historycznie

opracowaną metodą estymacji jest metoda największej wiarygodności z ograniczoną informacją, która znana jest również pod nazwą metody najmniejszego ilorazu wariancji. Właściwe zastosowanie zmiennych jakościowych, w tym sztucznych, szczególnie wobec braku jednolitego podejścia metodycznego powodować może kwestionowanie efektywności opracowanych nowych metod prognostycznych, a złożoność rozważań i poziom skomplikowania aparatu matematycznego nie są zbieżne z założonym w rozprawie celem opracowania metody autoregresyjnej prognozowania zapotrzebowania na moc elektryczną, która jednocześnie jest metodą wymagającą niewielkich nakładów czasowych wynikających z ograniczenia złożoności metody i dedykowanej jej założeń.

Dziewiąty element składowy to modele nieliniowe i modele oczekiwań [217]. Do podstawowych dwóch założeń dotyczących modeli ekonometrycznych regresji prostej i regresji wielorakiej należą założenie o liniowości między zmiennymi i założenie o rozkładzie normalnym składnika losowego. Niespełnienie drugiego warunku określane za pomocą testów statystycznych prowadzi do konieczności identyfikacji rozkładu innego niż normalny (np. gamma, log – normalny). Do modeli nieliniowych należą m.in. modele Boxa – Coxa, logitowy, probitowy i tobitowy. Analizy modeli nieliniowych i oczekiwań przeprowadzane są przy złagodzeniu wskazanych założeń. Modele nieliniowe szacowane są za pomocą metody optymalizacji Newtona – Raphsona (rozwijania funkcji w szereg Taylora drugiego rzędu), za pomocą metody Gussa – Newtona, a następnie estymowane są za pomocą nieliniowej metody najmniejszych kwadratów. Modele oczekiwań w odniesieniu do badań związanych z zagadnieniem prognozowania zapotrzebowania na moc elektryczną w systemach elektroenergetycznych nie są w praktyce stosowane, ponieważ stanowią domenę dziedzin bazujących na badaniach ankietowych. Założenie o normalności rozkładu szeregów czasowych, odzwierciedlających kształtowanie się zapotrzebowania na moc elektryczną w KSE, na podstawie testów statystycznych, nie daje potwierdzenia tego założenia.

Dziesiąty element składowy to błędy w zmiennych [217]. Błędy w zmiennych wynikają z korelacji między składnikami losowymi i zmiennymi objaśniającymi [217], [113], [176], [119], [372], [125]. Uzyskanie zgodnych estymatorów parametrów, czyli pozbawionych błędów, jest zagadnieniem złożonym i trudnym, jednakże nie uniemożliwia wnioskowania. Błędy w zmiennych wynikają z błędów rejestracji danych i użycia niedoskonałej miary (zmienna zastępcza – ang. *Proxy Variable*) dla prawdziwej zmiennej, która często jest niemierzalna (zmienna ukryta – ang. *Latent Variable*) [217]. Zaproponowana w pracy metodyka prognozowania zapotrzebowania na moc elektryczną w KSE bez użycia zmiennych objaśniających niweluje występowanie istotnych błędów w zmiennych, ze względu na autoregresyjny charakter opracowanego podejścia. Same wartości zapotrzebowania na moc elektryczną w KSE, w szczególności w sytuacji obecnego opomiarowania i stanu technologii informatycznych oraz przetwarzania danych pomiarowych [45], [60] można uznać za pozbawione błędów wpływających na jakość prognozowania, w szczególności wobec skali analizowanego zjawiska.

Jedenasty element składowy to diagnostyka, wybór modelu i testowanie specyfikacji [217]. Do zagadnień diagnostycznych zaliczono wcześniej kwestie testowania stabilności, heteroskedastyczności oraz testy autokorelacji bazujące na resztach wyznaczonych dla modeli oszacowanych metodą najmniejszych kwadratów [217]. Testy tego typu, zastosowane dla analizy pojedynczego szeregu czasowego, w sposób jednoznaczny korespondują z tematyką rozprawy. Zjawisko heteroskedastyczności i autokorelacji, przy zastosowaniu zmiennych objaśniających, rozważane z uwzględnieniem wyłącznie reszt metody najmniejszych kwadratów otrzymanych w wyniku szacowania równania regresji metodą najmniejszych kwadratów [217], generuje problem polegający na wykazywaniu przez te reszty obu analizowanych właściwości nawet jeśli w rzeczywistości składnik losowy ma stałą wariancję i nie podlega autokorelacji [217]. Wynika to z faktu, że obie te właściwości zależą od konkretnych wartości zmiennych objaśniających w próbie, co jest przyczyną występowania obszaru braku decyzji w teście Durбина – Watsona [217]. Opracowana w rozprawie metoda uwzględniająca jedynie autoregresyjne właściwości szeregu czasowego opisującego kształtowanie zmienności zapotrzebowania na moc elektryczną w KSE niweluje wspomniany problem reszt wobec braku występowania w modelu prognostycznym zmiennych objaśniających.

W odniesieniu do modeli ekonometrycznych wykorzystujących zmienne objaśniające (ich diagnostyka, dobór oraz testowanie ich specyfikacji) przybrały na znaczeniu wraz z rozwojem oprogramowania komputerowego [98] w latach osiemdziesiątych dwudziestego wieku. Programy te, dzięki wbudowanym narzędziom weryfikacji modeli, utorowały drogę do pogłębionych badań dotyczących wykrywania ich słabych stron. Do testów diagnostycznych opartych na resztach metody najmniejszych kwadratów stosuje się m.in.: testy pominiętych zmiennych, testowanie efektów ARCH (ang. *Autoregressive Conditionally Heteroskedastic Model*) [99], [217]. Do wykrywania nietypowych obserwacji stosuje się odpowiednie rodzaje reszt tj. [217]: reszty predyktywne, studentyzowane, BLUS, rekurencyjne; oraz stosuje się kryterium *Difference of Fits* (ang.) [19], estymację ograniczonego wpływu [185], test błędu specyfikacji Hausmana [137], test różnicowy oraz testy niezagnieżdżone [112], [217].

W sytuacji (teoretycznie) idealnej, w teorii ekonometrii zakłada się, że model opisujący badane zagadnienie, jest z góry znany, a zadaniem badacza jest uzyskanie dobrych oszacowań jego parametrów. Praktyczne czynności wskazują jednakże, że wybór modelu dokonywany jest po przeprowadzeniu wstępnej analizy zgromadzonych danych. Istnieje cienka granica pomiędzy idealistycznym podejściem metodycznym budowania modeli ekonometrycznych, a stosowanymi praktykami. Takie podejście skutkuje określeniem wstępnej oceny danych w nawet najprostszym zagadnieniu regresyjnym (błędy standardowe, reszty) jako przejścia do zagadnień *Data Mining* (zgłębiania danych), które przez wiele lat były postrzegane jako niedopuszczalne i funkcjonowały na „marginesie” idealnej ekonometrii.

Zagadnienie wyboru modelu prognostycznego obejmuje aspekty tj. [217]: wybór z grupy modeli zbudowanych przed rozpoczęciem analizy danych, upraszczanie skomplikowanych modeli na podstawie analizy danych, budowanie modelu

po dokonaniu analizy danych. Pozostałe aspekty wyboru modelu prognostycznego to dobór zmiennych objaśniających i zastosowanie metod wyboru modelu według kryterium prognostycznego [217]. Podstawy tematyki wyboru modelu prognostycznego omówiono m.in. w [65], [194], [232], [277]. W [194] zaproponowano pięć metod specyfikacji (wyboru modeli), które należy wzbogacić ideą upraszczania zaproponowaną w [143]. Grupa sześciu podstawowych metod obejmuje: weryfikację hipotez, interpretację danych zawartych w próbie dotyczących wielu współzależnych zmiennych, upraszczanie, zmiennych zastępczych, poszukiwanie danych, konstruowanie modelu po wstępnej analizie danych [217].

Powzięty w rozprawie cel empirycznego zastosowania metod ekonometrycznych w nowym ujęciu w zagadnieniu prognozowania zapotrzebowania na moc elektryczną w KSE napotyka na wielość definicji i określania samego zjawiska oraz wielość definicji i trybów postępowania w ciągu całego procesu opracowania i oceny nowego podejścia. Problem wyboru zmiennych został usunięty z całego procesu poprzez skupienie badań nad metodą autoregresyjną. Tym samym usunięty został problem pracy z różnymi zbiorami danych i błędami ich oszacowań. Większość empirycznych zastosowań ekonometrii opiera się na rozumowaniu podobnym do wnioskania Sherlocka Holmesa [217], [194] stosowanym po wstępnej analizie danych, co stoi w sprzeczności z klasyczną teorią statystyki. W zależności od przyjętego wnioskania istnieje ryzyko sformułowania fałszywych wniosków. Zastosowane w rozprawie podejście spopularyzowane w [143] i [232] polega na budowie modelu ogólnego i przejściu do modelu szczególnego – w przypadku rozprawy dzięki optymalizacji doboru liczby opóźnień (wobec braku uwzględniania zmiennych objaśniających, co wynika z autoregresyjnej postaci opracowanej metody). W rozprawie badania rozpoczęto od podstawowego modelu matematycznego, sformułowano zależność reprezentującą zaproponowaną teorię, oszacowano równania na podstawie dostępnych danych, przeprowadzono testy autokorelacji, skorygowano specyfikację modelu na podstawie otrzymanych wyników, ponownie oszacowano model.

Kwestia doboru zmiennych objaśniających w świetle zaproponowania w rozprawie nowej metody autoregresyjnej nie jest przedmiotem jej rozważań. W analizach modeli regresyjnych w doborze zmiennych objaśniających stosowane są kryteria wyboru polegające na minimalizacji średniokwadratowego błędu predykcji tj. kryteria Theila, Mallowsa, Hockinga, Memiyi, Akaike'a [217]. Zastosowanie kryteriów wyboru modelu, w sytuacji uwzględniania w modelu zmiennych objaśniających, skutkować może uzyskaniem modelu najlepiej dopasowanego do zgromadzonych danych, nie zaś modelu odpornego na przyszłe zmiany wartości objaśnianego parametru i tym samym najkorzystniejszego w sensie przyszłej jakości prognozowania. Środkiem zaradczym przy takim podejściu jest wybór modelu według kryterium prognostycznego (ang. *Cross Validation*) polegającego na podziale zbioru zgromadzonych obserwacji na podzbiór służący do estymacji i podzbiór przeznaczony do predykcji. Analizy pierwszego zbioru skutkują otrzymaniem błędów predykcji wewnątrz próby i odpowiednio z drugiego zbioru otrzymywane są błędy predykcji poza próbą. Model o najmniejszej sumie kwadratów błędów predykcji wybiera się jako najlepszy [217]. Brak zmiennych

objaśniających w opracowanym w rozprawie modelowaniu skutkuje brakiem konieczności stosowania kryteriów ich doboru. Pomimo braku zmiennych objaśniających w proponowanym podejściu skorzystano z podejścia walidacji krzyżowej. Pierwsza część badań skupia się na modyfikacjach opóźnień czasowych dla z góry ustalonych zakresów danych historycznych, przy stałym podziale na zbiór estymacji i predykcji. W drugiej części eksperymentu badania skupiają się na modyfikacjach zakresu danych historycznych przy stałych wartościach opóźnień czasowych i stałym podziale na zbiór estymacji i predykcji. Uzyskanie korzystniejszych wyników eksperymentu na podstawie drugiej jego części pozwoliło na analizę danych historycznych następujących po zakresie czasowym mającym miejsce po przedziale czasu koniecznym do „nauczenia” najlepszego modelu prognostycznego.

Dwunasty element składowy to analiza szeregów czasowych [217]. Analiza szeregów czasowych skupia się głównie na modelach autoregresyjnych (AR – ang. *AutoRegressive*) i modelach średniej ruchomej (MA – ang. *Moving Average*). Szeregi czasowe poddawane są ocenie stacjonarności i niestacjonarności, a następnie stosowane jest podejście Boxa – Jenkinsa do modelowania szeregów czasowych. Podejście to polega na różnicowaniu szeregu czasowego i wzrokowej ocenie korelogramu autokorelacji i autokorelacji cząstkowych [217]. Jedną z miar oceny jakości dopasowania modeli szeregów czasowych jest współczynnik determinacji R^2 . W dwudziestym wieku badacze pracowali w hermetycznych środowiskach czystej teorii ekonomii i analizy szeregów czasowych. Naukowcy podkreślający w sposób purystyczny znaczenie ekonomii skupiali swoje rozważania badawcze na zależnościach między zmiennymi poświęcając niewiele uwagi rosnącej dynamice zmian gromadzonych danych, podczas gdy badacze szeregów czasowych skupiali uwagę na sile samych danych w kreowaniu modeli prognostycznych. Ostatnie dwie i pół dekady dwudziestego wieku wskazują na rosnące przenikanie się tych nurtów z korzyścią dla obu grup badaczy. Szeregi czasowe klasyfikuje się jako stacjonarne i niestacjonarne. Zaletą podejścia autoregresyjnego jest możliwość szacowania za pomocą metody najmniejszych kwadratów. Stosowanie współczynnika determinacji dla oceny jakości dopasowania modeli szeregów czasowych wykazujących wyraźny trend jest niewystarczające, dlatego też w rozprawie wykorzystywana jest ocena jakości modelu (skuteczności prognozowania) za pomocą otrzymywanych wartości błędów prognoz. W przypadku modeli łączących element autoregresyjny i średniej ruchomej dążenie do uzyskania stacjonarności szeregu (poprzez różnicowanie) może powodować zanik informacji o zmianach długookresowych, co w przypadku zastosowanego w rozprawie podejścia, bazującego na podejściu autoregresyjnym i jednoczesnym wykorzystaniu informacji o autokorelacjach cząstkowych, nie ma miejsca wobec braku różnicowania szeregu czasowego.

Trzynasty element składowy to autoregresja wektorowa, pierwiastki jednostkowe i kointegracja [217]. Wskazane elementy stanowią rozwinięcie osiągnięć naukowych z lat siedemdziesiątych dwudziestego wieku w zakresie analizy szeregów czasowych i zostały opracowane w latach osiemdziesiątych i dziewięćdziesiątych dwudziestego wieku. Elementy te skupiają się głównie na analizie związków między wieloma

szeregiami czasowymi [217] i nie mają bezpośredniego związku i wpływu na rozważania zamieszczone w rozprawie. Wskazane elementy (modele) służą do analizy i estymacji modeli niestacjonarnych szeregów czasowych i są to: modele autoregresji wektorowej (VAR), pierwiastki jednostkowe oraz kointegracja. Modele autoregresji wektorowej pozwalają na analizę związków pomiędzy wieloma szeregami czasowymi, pierwiastek jednostkowy umożliwia analizę szeregów czasowych niestacjonarnych, w których pierwsze przyrosty są stacjonarne, natomiast teoria kointegracji pozwala zrozumieć w jaki sposób badać związki między długookresowymi trendami zmiennych, które w metodach Boxa – Jenkinsa eliminuje się przez różnicowanie [217].

Czternasty element składowy to analiza danych panelowych [217]. Analizy tego typu wykorzystywane są głównie w naukach ekonomicznych i stosują one połączenie informacji zawartych w szeregach czasowych z danymi przekrojowymi. Tym samym zachodzi wymieszanie próby, której efektem jest powstanie próby przekrojowo – czasowej [349]. Do analizy danych panelowych wykorzystywane są m.in.: modele z efektami ustalonymi, modele z efektami losowymi, modele pozornie niezwiązanych równań regresji [217]. W odniesieniu do analiz związanych z oceną parametrów funkcjonowania systemów elektroenergetycznych analizy tego typu opracowywane są w powiązaniu z funkcjonowaniem społeczeństwa (czyli poziomu najniższych napięć) i na przykład zużycia energii elektrycznej przypadającej na mieszkańca lub z uwzględnieniem innych kryteriów z zakresu nauk socjologicznych. Wobec rozpatrywania w rozprawie zapotrzebowania na moc elektryczną w KSE jako całości i uwzględnienia wyłącznie jednego szeregu czasowego odzwierciedlanego wartościami pomiarowymi (ilościowymi), analizy panelowo nie są bardziej szczegółowo w niej opisywane.

Piętnasty element składowy to teoria dużych prób [217]. Teoria dużych prób wykorzystuje metodę największej wiarygodności, metody rozwiązywania równań wiarygodności, dolną granicę Rao – Cramera oraz testy istotności dla dużych prób [29], oparte na metodzie największej wiarygodności (test ilorazu wiarygodności, test Walda, test scoringowy Rao, znany też jako test mnożnika Lagrange’a) [217]. Zagadnienie to związane jest z budowaniem modeli prognostycznych z wykorzystaniem zmiennych objaśniających i tym samym nie jest powiązane z rozważaniami zawartymi w rozprawie.

Szesnasty element składowy to metody próbkowania w małej próbie [217]. Metody te wykraczają poza zakres rozważań zawartych w rozprawie, ponieważ zgromadzony szereg czasowy stanowi dużą próbę. Niemniej jednak w tym kontekście należy wymienić dwie główne metody polegające na powtarzalnym losowaniu prób. Do metod tych zalicza się metody *Monte Carlo* i metody *Bootstrap* – pierwszą z nich wykorzystuje się w celu dokonania wyboru między dwoma estymatorami, czy też dwiema statystykami testowymi; druga pozwala na otrzymanie rozkładu z próby dla wybranego estymatora lub dla statystyki testowej [217].

Zestawienie elementów ekonometrii pokrótce opisanych powyżej prezentuje Rysunek 1.1.1. Znakiem w kolorze zielonym oznaczono wykorzystanie zagadnienia w rozprawie, a znakiem w kolorze czerwonym jego brak.

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*



Rys. 1.1.1. Elementy ekonometrii wykorzystane w rozprawie.

Źródło: Opracowanie własne na podstawie opisu dziedzin ekonometrii.

1.2. Prognozowanie w kontekście statystyki

Statystyka to nauka o metodach badania prawidłowości występujących w zjawiskach masowych. Ma zastosowanie we wszystkich dziedzinach wiedzy, gdzie badacz ma do czynienia z analizą danych [183], [285], [346]. Gromadzone obserwacje są reprezentowane przez wartości liczbowe. Wartości liczbowe w wielu przypadkach stanowią złożenie czynników głównych, zwanych czynnikami systematycznymi i czynników pośrednich, zwanych czynnikami losowymi. Czynniki pośrednie, będący często czynnikiem losowym, zakłóca w sposób znaczący analizę danych i tym samym budowę modelu prognostycznego. Statystyka, w której funkcjonują metody ilościowe analizowania danych i procesów poddawanych analizie, stanowi narzędzie wspomagające cały proces ekonometrycznych podstaw budowy modeli prognostycznych i tym samym prognozowania wybranych zjawisk. Głównymi narzędziami statystyki jako dziedziny nauki są: rachunek prawdopodobieństwa [126], [106], [354], statystyka opisowa i statystyka matematyczna [283]. W rachunku prawdopodobieństwa można wyodrębnić sześć następujących, głównych zagadnień [183]: zdarzenia losowe i prawdopodobieństwo (1.1), zmienne losowe jednowymiarowe (1.2), rozkłady prawdopodobieństwa zmiennej losowej skokowej (1.3), rozkłady prawdopodobieństwa zmiennej losowej ciągłej (1.4), zmienne losowe wielowymiarowe (1.5) oraz twierdzenia graniczne (1.6). Na statystyki opisowe składają się [183] nieparametryczny opis rozkładu w próbie (2.1) i parametryczny opis rozkładu w próbie (2.2). Statystyka matematyczna składa się z jedenastu głównych zagadnień, do których zalicza się [183]: rozkłady z próby (3.1), estymację parametrów populacji generalnej (3.2), weryfikację hipotez statystycznych (3.3), testy statystyczne dla populacji jednowymiarowej (3.4), testy statystyczne dla dwóch populacji (3.5), testy statystyczne dla wielu populacji (3.6), badanie współzależności zjawisk (3.7), analizę regresji (3.8), klasyczne metody analizy szeregów czasowych (3.9), elementy teorii procesów stochastycznych (3.10), prognozowanie na podstawie modeli *ARIMA* (3.11). W kontekście rozważań zawartych w rozprawie, czyli opracowania prognostycznej metody autoregresyjnej, do kluczowych elementów statystyki matematycznej zaliczyć należy ostatnie trzy obszernie jej działy, czyli wyszczególnione wcześniej klasyczne metody analizy szeregów czasowych, teorię procesów stochastycznych i wybrane zagadnienia z zakresu prognozowania na podstawie modeli *ARIMA*. Zestawienie elementów statystyki opisanych powyżej i wykorzystanych w rozprawie prezentuje Rysunek 1.2.1. Znakiem w kolorze zielonym oznaczono wykorzystanie zagadnienia w rozprawie, a znakiem w kolorze czerwonym jego brak.



Rys. 1.2.1. Elementy statystyki wykorzystane w rozprawie.

Źródło: Opracowanie własne na podstawie opisu dziedzin statystyki.

1.3. Prognozowanie w kontekście energetyki i elektroenergetyki

1.3.1. Zapotrzebowanie na moc elektryczną a obciążenie systemu elektroenergetycznego

Ze względu na specyfikę energii elektrycznej jako towaru, który cechuje się brakiem możliwości bezpośredniego substytuowania oraz ograniczoną możliwością akumulowania w systemie, wytwórcy wielkoskalowi, przedsiębiorstwa przesyłowe i dystrybucyjne zajmują się prognozowaniem wielkości zapotrzebowania na moc elektryczną z odpowiednim wyprzedzeniem i dokładnością. Wspomniane podmioty dzięki zastosowaniu urządzeń pomiarowych, systemów sterowania i nadzoru na bieżąco oceniają obciążenie (ang. *Load* [269]) systemów elektroenergetycznych mocą czynną [10], [78], [77], [83], [116], [122], [123], [258] i porównują z chwilowym zapotrzebowaniem na moc elektryczną. Wynikiem takiego porównania jest informacja, że obciążenie systemu jest za małe lub za duże w odniesieniu do chwilowego zapotrzebowania na moc elektryczną. Dzięki zastosowaniu prognozowania do planowania pracy systemów elektroenergetycznych możliwe jest zminimalizowanie odchyleń pomiędzy obciążeniem systemu elektroenergetycznego mocą czynną elektryczną (P) i zapotrzebowaniem na tę moc. Drugą ważną zaletą zastosowania technik prognostycznych jest pozyskanie informacji o niezbędnym do wytworzenia wolumenie mocy elektrycznej ze stosownym wyprzedzeniem. Prognozowanie zawsze obarczone jest niepewnością, która kształtowana jest najczęściej przedziałowo. Prognozowanie prawie zawsze obarczone jest błędem, tzn. prawie nigdy sprawdzalność prognozy, wynikająca z różnicy prognozy i jej wykonania, nie jest doskonała. Sporadyczne idealne wykonanie prognozy zapotrzebowania na moc elektryczną wskazuje, że w większości przypadków występują błędy prognoz. Błędy te w realiach dynamicznie rozwijających się rynków energii elektrycznej są kosztowne. Koszty błędów dodatnich (zawyżenie prognozy) wynikają z konieczności redukcji pracy bloków wytwórczych. Koszty błędów ujemnych (zaniżenie prognozy) wymuszają zakup energii droższej, co wynika z braku jej zakontraktowania z odpowiednim czasowym wyprzedzeniem.

W Polsce do końca dwudziestego wieku wystarczającym podziałem na horyzonty prognostyczne były prognozy wieloletnie i krótkoterminowe. Horyzont wieloletni obowiązywał od jednego roku, pięciu lat, dziesięciu, piętnastu i dwudziestu lat. Horyzont

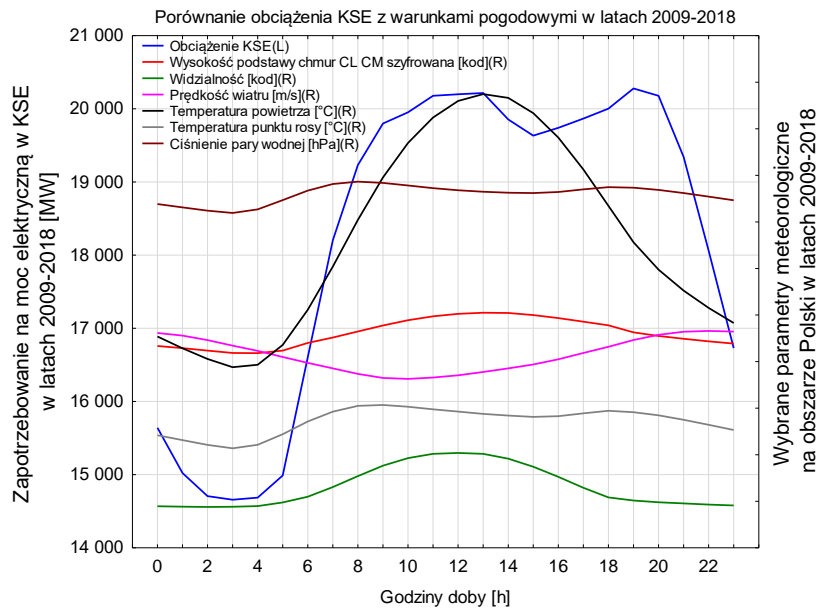
krótkoterminowy dotyczył wyprzedzenia jednej godziny, sześciu, dwunastu, dwudziestu czterech, czterdziestu ośmiu, stu sześćdziesięciu ośmiu godzin, jednego miesiąca i jednego roku. Prognozy w horyzoncie wieloletnim wykorzystuje się do planowania rozwoju systemów elektroenergetycznych oraz do planowania remontów kapitalnych elementów KSE, natomiast prognozy krótkoterminowe stosowane są m.in. do bieżącego zarządzania pracą elektrowni i sieci przesyłowej, do planowania remontów bieżących, planowania zakupów paliwa do elektrowni ciepłych, do zarządzania zbiornikami elektrowni wodnych [78].

1.3.2. Dynamika obciążenia systemu elektroenergetycznego w czasie

System elektroenergetyczny (SEE) obciążany jest mocą elektryczną czynną co wynika ze złożenia składowych przebiegów obciążeń odbiorników [178], [179]. Odbiorniki (odbior z punktu widzenia SEE), będące urządzeniami przyłączanymi do sieci elektroenergetycznych od poziomu najniższych napięć wzwyż, posiadają różne przeznaczenie użytkowania ze względu na indywidualny rytm pracy i odpoczynku odbiorców. Przebieg obciążenia systemu ze względu na zapotrzebowanie odbiorców można rozpatrywać jako funkcję losową zmiennej losowej (obciążenia). Przebieg obciążenia SEE powstaje w wyniku dodawania przebiegów obciążeń jego odbiorów składowych, jest więc sumą takich funkcji [78]. Obciążenie SEE, wynikające z poboru mocy przez zbiór wielu odbiorów, wynika również z oddziaływania czynników zewnętrznych (stymulant [290]) tj. zmiany warunków pogodowych, zmiany pór roku, czy zmiany nawyków społeczeństwa (dni świąteczne [22]), w tym rozwoju technologii zwiększających poziom zapotrzebowania i zmniejszające ten poziom (w tym rozwój instalacji wytwórczych prosumenckich [61]). Wiele ze zmiennych składowych tych czynników podlegając zmianom jest ze sobą skorelowanych. Funkcjonowanie odbiorników w czasie, odzwierciedlanych przebiegami ich obciążenia, na które wpływ mają czynniki losowe, wpływa poprzez ich złożenie na sumaryczne obciążenie SEE. Czynniki posiadającymi właściwości nieprzypadkowe, które wpływają na sumaryczne obciążenie SEE, są czynniki wynikające z właściwości położenia geograficznego danego SEE. Do czynników tych należą m.in. (i) typ klimatu i jego zmiany, (ii) wysokość położenia słońca i związane z nim padanie promieni słonecznych, (iii) momenty wschodów i zachodów słońca i wynikająca z nich długość trwania dnia i nocy. Każdy z SEE z uwzględnieniem położenia geograficznego posiada unikalną strukturę odbiorów cząstkowych, co wynika m.in. z profilu zaawansowania technologicznego danego kraju. Poszczególne SEE podlegają zróżnicowanym regulacjom determinowanym przez cykl życia społeczeństw i tym samym określają cykl funkcjonowania odbiorów składających się na wypadkowe ich obciążenie. Cykl funkcjonowania społeczeństwa (odbiorcy komunalni i instytucjonalni), tym samym użytkowanych przez nich odbiorów energii elektrycznej, określa kształtowanie ostatecznej postaci profilu obciążenia SEE i mniejszy ładunek losowości niż kwestie zmiany warunków pogodowych wynikających ze zmian klimatu. Znaczącym czynnikiem wprowadzającym wielość informacji losowych do profilu obciążenia SEE są awarie

urządzeń odbiorczych, czy też zmiany struktury posiadanych odbiorów wśród użytkowników. Awarie urządzeń wynikają m.in. z błędów ludzkich w sposobie ich prawidłowego użytkowania i coraz częściej programowanego wynikają z cyklu ich życia. Struktura odbiorników w danym gospodarstwie domowym [144] wynika m.in. ze stopnia zamożności społeczeństw, dostępności technologii, czy zmian cen energii elektrycznej. W ramach zmiany struktury odbiorników zauważalny jest wpływ rosnącej niezależności wśród użytkowników, który wynika m.in. z rozwoju energetyki prosumenckiej [61], czyli lokalnego zaspokajania potrzeb energetycznych w wyniku coraz powszechniejszego stosowania własnych źródeł zaspokajania potrzeb bytowych. Użytkownicy tego typu w coraz większym stopniu wpływają na obniżenie całkowitego obciążenia SEE i pomimo braku znaczących zmian w strukturze samych odbiorników zmniejszają wielkość poboru energii w odniesieniu do SEE jako całości. Dynamiczny wzrost użytkowania paneli fotowoltaicznych w latach 2019 – 2021 doprowadził w KSE do osiągnięcia mocy w nich zainstalowanej do poziomu 5,23 GW (stan na dzień 30 czerwca 2021 roku wg PSE S.A.) co w sposób jednoznaczny przekłada się na zmniejszenie obciążenia samego KSE. Znaczącym czynnikiem wpływającym na obciążenie SEE, wynikającym z funkcjonowania klimatu (położenia geograficznego), jest zaspokajanie komfortu termicznego odbiorców. Tym samym obciążenie każdego SEE jest związane z charakterem zmian klimatu i posiada cechy zjawiska przyrodniczego, co pokazują Rysunki 1.3.2.1 i 1.3.2.2, na których przedstawione jest porównanie średniego obciążenia KSE z wybranymi średnimi wartościami niektórych parametrów meteorologicznych. Bazując na ogólnodostępnych publikacjach i badaniach własnych odnotowuje się, że temperatura powietrza w znaczącym stopniu wpływa na wartość zapotrzebowania na moc elektryczną w KSE, w szczególności na tle pozostałych analizowanych parametrów meteorologicznych. Silna zależność tych parametrów jest zauważalna szczególnie w pierwszej połowie doby. Parametry pogodowe zaprezentowane na Rysunku 1.3.2.1 i Rysunku 1.3.2.2, ze względu na długi okres uśredniania obejmujący 10 lat kalendarzowych i ujęcie na jednej skali lewej osi pionowej, nie wykazują, poza temperaturą powietrza, dużych wartości narastania i opadania zboczy wykresów, niemniej jednak zauważalne jest jednoznaczne powiązanie obciążenia KSE z analizowanymi przebiegami wybranych parametrów pogodowych. Parametrami pogodowymi, których wartości średnie zwiększają się od godzin nocnych do godzin południowych należą (Rysunek 1.3.2.1): temperatura powietrza, wysokość podstawy chmur oraz widzialność. Prędkość wiatru (Rysunek 1.3.2.1) w godzinach południowych osiąga swoje minimum. Temperatura punktu rosy i ciśnienie pary wodnej osiągają dwa szczyty, które powiązane są z chwilami występowania szczytów w przebiegu krzywej zapotrzebowania na moc elektryczną w KSE (Rysunek 1.3.2.1).

Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną metodą ważonych współczynników funkcji autokorelacji cząstkowej

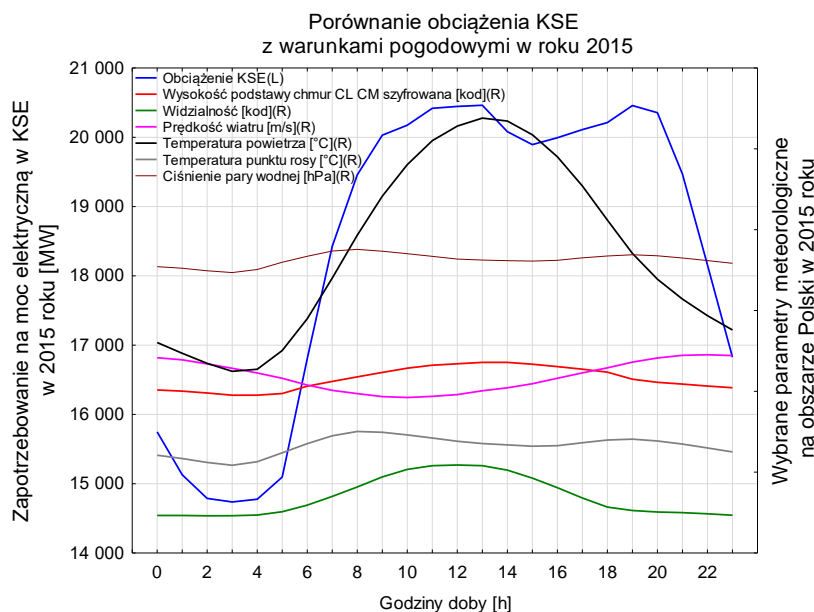


Rys. 1.3.2.1. Zmienność średniego obciążenia dobowego KSE w latach 2009 – 2018 na tle średnich wartości wybranych parametrów meteorologicznych monitorowanych przez IMGW na terenie Polski.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256] i IMGW [151].

Rysunek 1.3.2.2 wskazuje na zmienność krzywej temperatury powietrza i podążającej za nią krzywej obciążenia KSE na przykładzie 2015 roku. Szczególnie zauważalne jest powiązanie stromości zbocza narastania obciążenia KSE w godzinach nocnych i przedpołudniowych z kształtowaniem wartości temperatury powietrza. W 2014 roku doszło do spłaszczenia krzywych parametrów pogodowych innych niż temperatura powietrza, której krzywa w sposób punktowy odwróciła trend swojego kształtowania o godzinie 03:00 w nocy w kierunku łagodnego kształtowania w pozostałych godzinach doby. Rok 2015 (Rysunek 1.3.2.2) charakteryzujący się bardzo gorącym latem i wprowadzeniem w KSE dwudziestego stopnia zasilania, w związku ze znaczącym i długo utrzymującym się zapotrzebowaniem odbiorców na moc elektryczną [254], wskazuje na punktowe wypiętrzenie temperatury powietrza o godzinie 14:00 i osiągnięcie zrównania szczytów zapotrzebowania w godzinach 11:00 i 19:00. Lato w 2015 roku, a w szczególności sierpień, w Polsce było ekstremalnie ciepłe oraz suche i było piątym najcieplejszym latem w historii obserwacji od 1781 r [71]. Średnia temperatura otoczenia w sierpniu wyniosła 21,3°C, a dla lata wyniosła 18,9°C [225]. W związku z powyższym dochodziło do niedoborów mocy i energii elektrycznej i zastosowania stopni zasilania [178]. Na niestały charakter poziomu obciążenia SEE wpływają przede wszystkim zmiany: pór roku, rytmu życia odbiorców wraz z ich zwyczajami i tradycjami [78]. Do najczęściej rozróżnianych zmienności SEE zaliczane są zmienność dobową [164], tygodniową i roczną [78]. Bardziej pogłębione analizy mogą skutkować identyfikacją miesięczną, kwartalną i półroczną. Krzywe obciążenia SEE uzyskuje się sumując obciążenia odbiorców przemysłowych, miejskich, wiejskich, trakcji elektrycznej oraz straty mocy na drodze przesyłu od źródła do odbiorcy, otrzymując krzywą dobowego obciążenia [78] KSE. Przykłady dla każdego roku analizy od 2009 roku do 2018 roku zaprezentowane są w Załączniku do rozprawy.

Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną metodą ważonych współczynników funkcji autokorelacji cząstkowej




Rys. 1.3.2.2. Zmienność średniego obciążenia dobowego KSE na przykładzie 2015 roku na tle średnich wartości wybranych parametrów meteorologicznych monitorowanych przez IMGW na terenie Polski.

Legenda: L: oś rzędnych lewa; R: oś rzędnych prawa.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256] i IMGW [151].


Rysunek 1.3.2.3 prezentuje zmienność średniego dobowego obciążenia KSE w okresie analizy od 2009 roku do 2018 roku. Ocena przebiegu kształtu wszystkich dziesięciu średnich dobowych krzywych obciążenia wskazuje, że krzywe te posiadają bardzo podobny kształt. Średnie zapotrzebowanie na moc elektryczną w ciągu całej doby rosło systematycznie co rok od 2009 roku. Największe różnice pomiędzy kolejnymi latami w czasie doliny nocnej zauważalne są pomiędzy rokiem 2016 i 2017. W odniesieniu do zwiększenia obciążenia KSE w szczycie przedpołudniowym największym jego przyrostem charakteryzował się 2010 rok, w porównaniu do 2009 roku. Takie samo zachowanie krzywej obciążenia KSE odnotowano dla szczytu wieczornego. W latach od 2011 roku do 2014 roku zauważalne były nieznaczne przyrosty średniego dobowego obciążenia, natomiast ostatnie cztery lata analizowanego okresu wskazują na systematyczne przyrosty obciążenia KSE. W 2009 roku średnie zużycie energii elektrycznej w KSE w ciągu całej doby wynosiło ok. 16 979 MWh (średnia ze wszystkich godzin doby), natomiast w 2018 roku średnia ta wynosiła ok. 19 532 MWh co stanowiło przyrost o 15,04%. Największą średnią wartością obciążenia KSE w ciągu doby w 2009 roku charakteryzowała się godzina 19:00 (18 904 MW) zaś najmniejszą godzina 03:00 z wolumenem na poziomie 13 911 MW. Różnica pomiędzy najmniejszym i największym obciążeniem średnim w ciągu doby w 2009 roku wyniosła 4 993 MW, co dało zmianę na poziomie 35,89%. Różnice w kolejnych latach, dla różnicy pomiędzy największym i najmniejszym średnim dobowym obciążeniem w KSE, wynosiły odpowiednio: 39,28% (2010 r. a 2009 r.); 39,19% (2011 r. a 2010 r.); 39,24% (2012 r. a 2011 r.); 39,74% (2013 r. a 2012 r.); 39,83% (2014 r. a 2013 r.); 38,86% (2015 r. a 2014 r.); 39,45% (2016 r. a 2015 r.); 38,24% (2017 r. a 2016 r.); 37,95% (2018 r. a 2017 r.). Największe różnice pomiędzy skrajnymi punktami przebiegu dobowej krzywej obciążenia KSE odnotowano kolejno w latach 2014, 2013 i 2016. Największą średnią wartością

obciążenia KSE w ciągu doby w 2018 roku, charakteryzowała się godzina 12:00 (21 726 MW); w 2009 roku była to godzina 19:00, zaś najmniejszą, analogicznie jak w 2009 roku, godziną 03:00 z wolumenem na poziomie 15 749 MW. Wartość obciążenia KSE w szczycie doby wzrosła w ciągu dziesięciu lat o 14,93% (z 18 904 MW do 21 726 MW), natomiast obciążenie KSE w dolinie zapotrzebowania na moc elektryczną wzrosło z poziomu 13 911 MW do poziomu 15 749 MW czyli o 13,21%. Lektura Rysunku 1.3.2.3 wskazuje, że średnie zapotrzebowanie na moc elektryczną w KSE w godzinach nocnych rosło, a dysproporcje pomiędzy wartościami ekstremalnymi kształtu krzywej obciążenia malały w porównaniu do pierwszego roku analizy. Tendencję tą należy uznać za korzystną z punktu widzenia pracy jednostek wytwórczych konwencjonalnych i wiatrowych. W przypadku jednostek konwencjonalnych i rosnącym średnim obciążeniu KSE mniejsza ich liczba będzie musiała przechodzić do wytwarzania na poziomie minimum technicznego i tym samym przy dużym udziale wytwarzania w źródłach wiatrowych będzie rzadko występowało ryzyko ograniczania ich generacji oraz jej wprowadzania do sieci przesyłowej generacji wiatrowej, w tym z niemieckiego elektroenergetycznego systemu przesyłowego (również wskutek nieplanowych przepływów mocy) [182], [181], [172], [8]. Zmiana uśrednionej dobowej krzywej obciążenia w analizowanym okresie wskazuje również, że doszło do odwrócenia trendu i zwiększenia obciążenia KSE w szczycie południowym na rzecz zmniejszenia tego obciążenia w czasie szczytu wieczornego. Zjawisko to w przyszłości może być korzystne ze względu na dynamiczny rozwój wytwarzania energii elektrycznej w źródłach fotowoltaicznych, które będą mogły wspomagać pokrycie zapotrzebowania w godzinach południowych, gdy oddziaływanie słońca będzie się w największym stopniu przyczyniało do produkcji energii elektrycznej za pomocą tych źródeł.



Rys. 1.3.2.3. Zmienność średniego obciążenia dobowego KSE w latach 2009 – 2018.
Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną metodą ważonych współczynników funkcji autokorelacji cząstkowej




Rys. 1.3.2.4. Zmienność średniego obciążenia dobowego KSE w poszczególnych miesiącach roku kalendarzowego w latach 2009 – 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Na Rysunku 1.3.2.4 przedstawiono zmienność średniego obciążenia dobowego KSE w poszczególnych miesiącach roku kalendarzowego dla całego dziesięcioletniego okresu analizy. W lutym średnio za okres dziesięciu lat dochodziło do największego obciążenia KSE (19 788 MW). Kolejnymi miesiącami w tym zestawieniu były styczeń, grudzień i listopad z zapotrzebowaniem na moc elektryczną odpowiednio na poziomie: 19 769 MW, 19 416 MW i 19 182 MW. Zauważalne jest występowanie trzech grup miesięcy o podobnych poziomach zapotrzebowania i kształtach krzywej obciążenia KSE. Pierwszą grupę stanowią miesiące o największym zapotrzebowaniu: styczeń, luty, listopad, grudzień. Drugą grupę stanowią miesiące marzec i październik o bardzo wysokiej zbieżności obu profili, zarówno w odniesieniu do kształtu jak i wielkości zapotrzebowania na moc elektryczną w KSE. Do trzeciej grupy zalicza się miesiące od maja do września. Miesiącem o najniższym średnim obciążeniu w okresie analizy był maj: 16 853 MW. Rysunek 1.3.2.5 prezentuje zmienność średniego dobowego obciążenia KSE w poszczególnych miesiącach lat kalendarzowych w okresie analizy dla poniedziałków od 2009 roku do 2018 roku. Obciążenie KSE w poszczególnych dniach tygodnia, z uwzględnieniem podziału na miesiące roku kalendarzowego, zachowywało takie same tendencje jak w przypadku wyłącznej analizy dla miesięcy roku za cały okres analizy. Średnie obciążenie KSE w okresie 10 lat dla poszczególnych dni tygodnia wyniosło 18 476 MW (poniedziałki), 19 132 MW (wtorki), 19 242 MW (środy), 19 156 MW (czwartki), 19 051 MW (piątki), 17 236 MW (soboty), 15 452 MW (niedziele). Dniem tygodnia o największym średnim obciążeniu w okresie dziesięciu lat analizy była środa. Na kolejnych dwóch miejscach pod tym względem uplasowały się czwartek i wtorek. Piątek i poniedziałek zajęły pod tym względem kolejne dwie pozycje. Poniedziałek jest pierwszym dniem w tym zestawieniu, w którym średnie obciążenie w KSE w badanym okresie odnotowano na poziomie niższym niż 19 000 MW. W związku z pięciodniowym systemem pracy w Polsce dni weekendowe

charakteryzowały się najniższym zapotrzebowaniem na moc elektryczną w KSE w porównaniu do dni roboczych. Zmniejszenie obciążenia w sobotę, przy 5 dniowym roboczym tygodniu jest zjawiskiem naturalnym tak samo jak zwiększenie obciążenia KSE w poniedziałek w porównaniu do niedzieli. Jako standardowe dni robocze określa się dni od wtorku do piątku [78]. Przykłady dla każdego roku analizy od 2009 roku do 2018 roku zaprezentowane są w Załączniku do rozprawy.




Rys. 1.3.2.5. Zmienność średniego obciążenia dobowego KSE w miesiącach dla poniedziałków w latach 2009 – 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].


Znaczącą rolę w prognozowaniu zapotrzebowania na moc elektryczną stanowią informacje o szczytowym zapotrzebowaniu na moc elektryczną w skali roku kalendarzowego. Taka informacja w podziale na szczyt roczny i szczyt letni umożliwia opracowanie rocznej prognozy zapotrzebowania na energię elektryczną, która jest stosowana nie tylko w opracowywaniu planów krótkoterminowych pracy KSE, ale także wykorzystywana jest w planach miesięcznych i rocznych, w tym również w odniesieniu do długoterminowego planowania rozwoju sieci przesyłowej [163], z uwzględnieniem tzw. scenariuszy klimatycznych. Maksymalne, czyli szczytowe, zapotrzebowanie na moc elektryczną w każdym roku analizy przedstawione jest na Rysunku 1.3.2.6. Oprócz podziału na kwartały lat kalendarzowych rysunek ten przedstawia przebieg wartości szczytowych obciążenia dla całego okresu analizy. Szczytowe roczne zapotrzebowanie na moc elektryczną w KSE odnotowano w pierwszym i czwartym kwartale roku kalendarzowego. Minimalne roczne zapotrzebowanie na moc elektryczną w KSE odnotowywane było dla kwartału drugiego i trzeciego. Zapotrzebowanie szczytowe roczne w latach 2009 – 2016 charakteryzowało się naprzemiennymi wzrostami i spadkami. Od 2017 roku obserwowane było rokroczne zwiększanie wartości szczytowego zapotrzebowania na moc w KSE. W kwartale drugim i czwartym naprzemienność występowania przyrostów i spadków wartości szczytowych obciążenia KSE została zachwiana i opóźniona jest o jeden rok w odniesieniu do rokrocznych przyrostów obciążenia KSE. Szczytowe wartości zapotrzebowania na moc w KSE

w kolejnych latach analizy kształtowały się w sposób następujący: 24 358 MW, 25 297 MW, 24 608 MW, 25 578 MW, 24 580 MW, 25 459 MW, 24 821 MW, 25 447 MW, 26 046 MW, 26 297 MW.



Rys. 1.3.2.6. Maksymalne zapotrzebowanie na moc elektryczną w KSE w latach i kwartałach lat 2009 – 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].




Rys. 1.3.2.7. Maksymalne zapotrzebowanie na moc elektryczną w KSE w miesiącach lat 2009 – 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Analiza przebiegów maksymalnych obciążeń KSE w podziale na miesiące lat okresu 2009 – 2018 (Rys. 1.3.2.7) wskazuje, że w każdym miesiącu zmiany obciążenia KSE utrzymywały się w trendzie wzrostowym. Miesiące od kwietnia do września charakteryzowały się większą dynamiką zmiany dla całego okresu w porównaniu do miesięcy od stycznia do marca i od października do grudnia. Przebiegiem o największej zmienności charakteryzował się luty. Największą zmianą rok do roku

w ostatnich dwóch latach analizy charakteryzował się przebieg dla marca (2 649 MW, czyli 11,20%). Maksymalne zapotrzebowanie na moc elektryczną w KSE w okresie dziesięciu lat analizy, w podziale na dni tygodnia, (Rys. 1.3.2.8) wskazuje na wystąpienie rosnącego trendu dla dni od poniedziałku do piątku. Soboty i niedziele pomimo zmiany zachowania tendencji w 2015 roku wykazują na niewielki trend wzrostowy w analizowanym okresie. Lato w 2015 roku charakteryzowało się znacznie większymi temperaturami otoczenia, a wprowadzenie w okresie letnim ograniczeń w dostawach energii elektrycznej nie pozostało bez wpływu na obniżenie wartości maksymalnego zapotrzebowania na moc w KSE. Dla soboty odwrócenie trendu w 2015 roku wyniosło 1 026 MW, czyli 4,50%, natomiast dla niedzieli zmiana wynikająca ze zmiany trendu wyniosła 1 071 MW, czyli 5,07%.




Rys. 1.3.2.8. Maksymalne zapotrzebowanie na moc elektryczną w KSE w dniach tygodnia lat 2009 – 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Minimalne zapotrzebowanie na moc elektryczną w KSE, zaprezentowane na Rysunku 1.3.2.9, w okresie analizy charakteryzowało się trendem wzrostowym. Podobnie jak w przypadku wartości maksymalnych obciążenia KSE w okresie tym dochodziło do naprzemiennego zwiększania i spadku analizowanego parametru, z wyjątkiem 2017 roku. Krzywa dla całego okresu analizy pokrywa się z krzywą wyznaczona dla pierwszego kwartału w okresach 2009 – 2014 i 2017 – 2018. Wartości minimalne dla kwartału drugiego i trzeciego charakteryzowały się mniejszym zróżnicowaniem w porównaniu do analogicznego wykresu dla wartości maksymalnych. Minimalne wartości zapotrzebowania na moc elektryczną w KSE w poszczególnych latach analizy kształtowały się w sposób następujący: 9 647 MW, 10 293 MW, 10 202 MW, 11 011 MW, 10 936 MW, 10 494 MW, 11 200 MW, 11 429 MW, 11 917 MW, 12 262 MW. Wyraźny podział na kwartał pierwszy i czwarty oraz drugi i trzeci nie był jednak zauważalny w przypadku wartości maksymalnych.


Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną metodą ważonych współczynników funkcji autokorelacji cząstkowej



Rys. 1.3.2.9. Minimalne zapotrzebowanie na moc elektryczną w KSE w latach i kwartałach lat 2009 – 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].


Analiza przebiegów minimalnych obciążeń KSE w podziale na miesiące w latach 2009 – 2018 (Rysunek 1.3.2.10) wskazuje, że w każdym miesiącu zmiany obciążenia KSE utrzymywały się w trendzie wzrostowym. Miesiące od kwietnia do września charakteryzowały się bardziej jednostajnymi zmianami dla całego okresu w porównaniu do miesięcy od stycznia do marca i od października do listopada. Najbardziej zmiennym przebiegiem charakteryzował się luty. Największą zmianą rok do roku dla 2017 roku w porównaniu do 2016 roku charakteryzował się przebieg dla marca (2 045 MW, czyli 17,23%).



Rys. 1.3.2.10. Minimalne zapotrzebowanie na moc elektryczną w KSE w miesiącach lat 2009 – 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Minimalne zapotrzebowanie na moc elektryczną w KSE w okresie dziesięciu lat analizy, w podziale na dni tygodnia (Rys. 1.3.2.11), wskazuje na występowanie trendu rosnącego dla wszystkich dni tygodnia. W przypadku wartości maksymalnych 2015 rok stanowił odstępstwo od podtrzymania trendu zachowań corocznych dla soboty i niedzieli. W odniesieniu do wartości minimalnych wskazany rok i gorące lato skutkowało zmniejszeniem wielkości zapotrzebowania na moc elektryczną również w sobotę, lecz zamiast niedzieli, dniem, w którym odnotowano zmniejszenie obciążenia KSE, zamiast zwiększenia, jest piątek. Nie odnotowano nieznacznego trendu wzrostowego jak to miało miejsce dla wartości maksymalnych. Dla soboty odwrócenie trendu w 2015 roku wyniosło 246 MW, czyli 2,15%, natomiast dla piątku zmiana wynikająca ze zmiany trendu wyniosła 103 MW, czyli 0,89%. Dla soboty i obserwacji minimalnego zapotrzebowania na moc elektryczną w KSE w porównaniu do maksymalnego zapotrzebowania na moc elektryczną w KSE zauważalna była bezpośrednia relacja na poziomie 76,02%, co oznacza, że spadek wartości minimalnej był znacząco mniejszy w 2015 roku niż dla wartości maksymalnej.



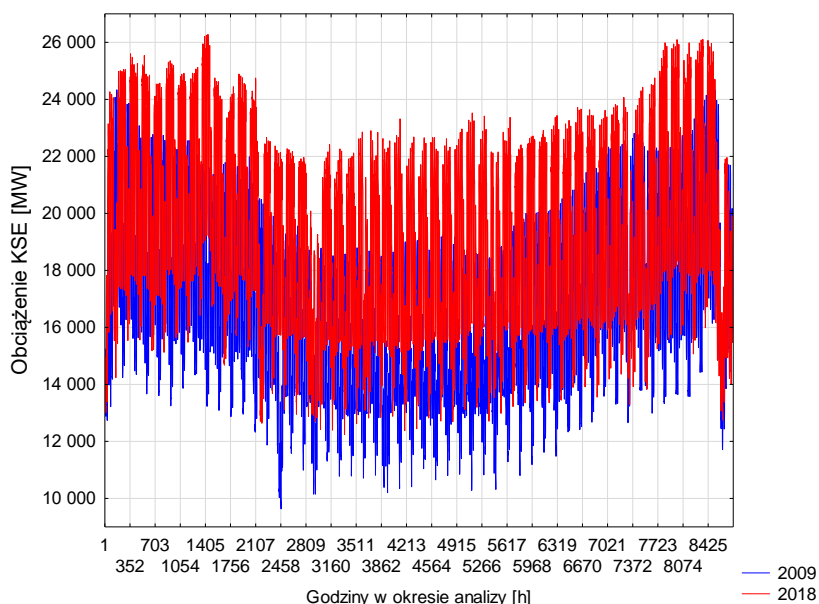
Rys. 1.3.2.11. Minimalne zapotrzebowanie na moc elektryczną w KSE w dniach tygodnia lat 2009 – 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Wyodrębnianymi punktami charakterystycznymi dla krzywych zmienności obciążenia KSE są: dolina nocna, szczyt poranny, dolina popołudniowa i szczyt wieczorny [78], [177], [186], [221]. Główną osią rozważań w rozprawie jest analiza zmienności obciążenia KSE w godzinach nocnych, z uwzględnieniem punktu doliny nocnej. Badania poszerzono o analizę pozostałych godzin każdej doby z analizowanego okresu 10 lat. Ciekawym punktem charakterystycznym krzywej obciążenia KSE jest szczyt wieczorny powiązany, z niewielkim opóźnieniem, z momentem występowania zachodu słońca. Zmiana obciążenia KSE w tym punkcie jest opóźniona o kilkadziesiąt minut względem momentu zachodu słońca i wynika z uruchamiania odbiorów oświetleniowych [72], [78], [107]. Zależność ta jest szczególnie interesująca w kontekście analizy wpływu

urzędowych zmian czasu oraz w odniesieniu do planów rezygnacji z dwukrotnej zmiany czasu w okresie roku kalendarzowego [46], [78], [77].

Szeregi czasowe będące złożeniem kolejnych godzin 2009 roku (pierwszy rok analizy) i 2018 roku (ostatni rok analizy) analizy prezentuje Rysunek 1.2.3.12. Dla celów ich wizualizacji usunięto z analizowanych danych historycznych dzień dwudziestego dziewiątego lutego występujący w latach przestępnych w 2012 roku i 2016 roku. Analiza Rysunku 1.2.3.12 wskazuje na przyrost zapotrzebowania na moc elektryczną pomiędzy pierwszym i ostatnim rokiem analizy. Każdy rok kalendarzowy z dziesięcioletniego zakresu analizy zaprezentowany jest w Załączniku do rozprawy, natomiast na Rysunku 1.3.2.13 przedstawiono szereg czasowy dla 2018 roku. Na obu rysunkach wyraźnie zauważalne są spadki zapotrzebowania na moc elektryczną w KSE w okresach świątecznych, czyli Świątach Wielkiej Nocy i Bożego Narodzenia i długich weekendach, czyli w maju i czerwcu.



Rys. 1.3.2.12. Obciążenie KSE w godzinach doby w latach 2009 – 2018.


Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Analiza kolejnych przebiegów dla lat kalendarzowych (Załącznik do rozprawy) wskazuje na systematyczne zwiększanie zapotrzebowania na moc elektryczną w KSE i osiągnięcie maksimum w 2018 roku.

Odstępstwo od regularnego kształtu szeregu czasowego nastąpiło dla lat 2013, 2016 i 2018, gdzie w pierwszym kwartale obciążenie KSE utrzymało się na równym poziomie. Do zróżnicowania poziomów obciążenia, stanowiących odstępstwo od systematycznych spadków obciążenia w pierwszym kwartale roku kalendarzowego, dochodziło w latach 2011, 2012, 2014 i pomimo utrzymania stałego zwiększonego poziomu zapotrzebowania, także w 2018 roku.

Przykłady dobowych krzywych obciążenia KSE w każdą trzecią środę lipca każdego analizowanego roku prezentuje Rysunek 1.2.3.14. Trzecia środa lipca jest określana jako środa pomiarowa [73], a zapotrzebowanie w tym dniu stanowi reprezentatywny przebieg krzywej obciążenia KSE dla okresu letniego.


Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną metodą ważonych współczynników funkcji autokorelacji cząstkowej



Rys. 1.3.2.13. Obciążenie KSE w godzinach doby w 2018 roku.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].


Do 2013 roku kolejne przyrosty były równomierne. W latach 2014 – 2016 (kolejne trzy lata analizy) różnice pomiędzy krzywymi były znikome. W 2017 roku nastąpił znaczący przyrost zapotrzebowania na moc elektryczną w KSE odzwierciedlany zmiennością kształtowania krzywej obciążenia KSE. Rok 2018 oznacza kolejny wzrost zapotrzebowania oraz zmianę kształtu krzywej od godziny 19:00 do godziny 21:00. Drugim charakterystycznym punktem analizy jest trzecia środa stycznia, która odzwierciedla reprezentatywny przebieg krzywej obciążenia dla okresu zimowego. Kolejne analizy na podstawie wizualizacji danych pomiarowych w KSE dotyczą stycznia i lipca, czyli reprezentatywnego okresu zimowego i letniego.



Rys. 1.3.2.14. Obciążenie KSE w godzinach doby w poszczególnych latach 2009 – 2018 w tak zwaną środę pomiarową.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].


Dobowy przebieg zapotrzebowania w czasie tworzy szereg czasowy. Szeregi czasowe odzwierciedlające złożenie kolejnych krzywych obciążenia KSE w styczniu i lipcu 2009 roku i 2018 roku przedstawiają odpowiednio Rysunki 1.3.2.15 i 1.3.2.16.



Rys. 1.3.2.15. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w styczniu w latach 2009 i 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Zróźnicowanie krzywych obciążenia KSE w lipcu dla 2009 roku w porównaniu do 2018 roku było większe w porównaniu do stycznia. Największe wartości najczęściej występowały w 2018 roku, a najniższe dla lat 2009 i 2011 (Załącznik).

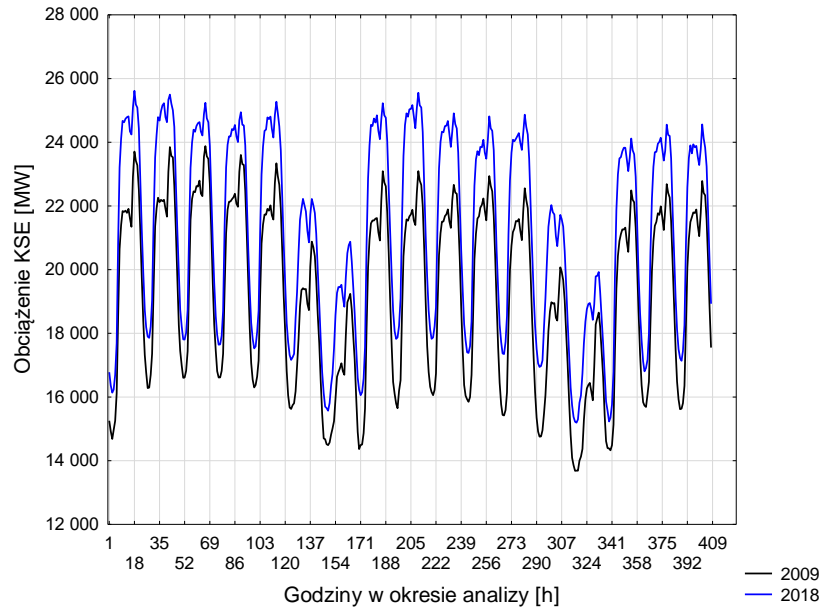


Rys. 1.3.2.16. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w lipcu w latach 2009 i 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Dla 2009 roku wykres przedstawiony na Rysunku 1.3.2.17 obejmuje kolejne dni tygodnia stycznia rozpoczynające się od poniedziałku 12 stycznia do środy 28 stycznia, natomiast dla 2018 roku prezentowany wykres, zbieżny z rokiem 2009 obejmuje

dni od poniedziałku 15 stycznia do środy 31 stycznia. W całym okresie analizy zauważalne było osiągnięcie większego obciążenia KSE w 2018 roku w porównaniu do 2009 roku. To samo porównanie w odniesieniu do różnicy pomiędzy szczytami wieczornymi wskazuje na zbliżanie się wartości szczytu południowego w kierunku szczytu wieczornego. Zrównywanie się szczytów jest wynikiem obowiązującego w styczniu czasu zimowego i zwiększania udziału urządzeń grzewczych w obciążaniu mocą elektryczną KSE.




Rys. 1.3.2.17. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w styczniu (17 dni) w latach 2009 i 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Dla 2009 roku zakres przedstawiony na Rysunku 1.3.2.18 obejmuje kolejne dni tygodnia lipca rozpoczynające się od poniedziałku 6 lipca do wtorku 28 lipca, natomiast dla 2018 roku prezentowany zakres, zbieżny z 2009 rokiem obejmuje dni od poniedziałku 9 lipca do wtorku 31 lipca. W całym okresie analizy zauważalne było osiągnięcie większego obciążenia w 2018 roku w porównaniu do 2009 roku – analogicznie jak w przypadku rozpatrywania okresu dla stycznia. To samo porównanie w odniesieniu do różnicy pomiędzy szczytami wieczornymi wskazuje na zbliżanie się wartości szczytu południowego w kierunku szczytu wieczornego dla niedzieli oraz znaczące wypiętrzanie szczytu południowego ponad wartości zapotrzebowania na moc elektryczną w KSE dla szczytu wieczornego. Odnotowana zależność jest wynikiem m.in. zwiększenia średnich temperatur powietrza i zwiększonego udziału urządzeń chłodniczych w obciążaniu mocą elektryczną KSE.


Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną metodą ważonych współczynników funkcji autokorelacji cząstkowej



Rys. 1.3.2.18. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w lipcu (23 dni) w latach 2009 i 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Wyodrębnienie pierwszego pełnego tygodnia (Rys. 1.3.2.19), czyli od poniedziałku do niedzieli, w styczniu 2009 roku i 2018 roku, wskazuje, że fluktuacje w godzinach szczytu południowego występujące w 2009 roku uległy złagodzeniu w 2018 roku dla wszystkich dni tygodnia. Zbliżenie szczytu południowego i wieczornego w największym stopniu dotyczyło czwartku, piątku i soboty.




Rys. 1.3.2.19. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w pierwszym pełnym tygodniu lipca w latach 2009 i 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Wyodrębnienie pierwszego pełnego tygodnia (Rys. 1.3.2.20), czyli od poniedziałku do niedzieli, w lipcu 2009 roku i 2018 roku, wskazuje, że stromość zbroczy narastania i opadania krzywej dla szczytu wieczornego w 2009 roku uległa złagodzeniu w 2018 roku dla wszystkich dni tygodnia.

Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną metodą ważonych współczynników funkcji autokorelacji cząstkowej



Rys. 1.3.2.20. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w pierwszym pełnym tygodniu lipca w latach 2009 i 2018.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

1.3.3. Gospodarka rynkowa a gospodarka planowa

Podmioty funkcjonujące w polskim systemie elektroenergetycznym obejmują swoją działalnością wytwarzanie, przesył, dystrybucję i obrót energią elektryczną [245]. Na rynku energii elektrycznej można wyróżnić trzy charakterystyczne segmenty handlu [231]: kontrakty bilateralne, transakcje giełdowe oraz rynek bilansujący [173], [229].

Znamienną cechą gospodarki planowej była niekonkurencyjność produktów na rynku wewnętrznym, a skala popytu i stopień jego zaspokojenia były określane przez centralnego planistę. Tym samym przemysł uzyskiwał wpływy finansowe za wykonanie planu produkcji, a nie za sprzedaż swoich wyrobów klientom [78]. Gospodarka planowa była dotowana przez państwo w oderwaniu od kosztów energii elektrycznej, ograniczeń nakładanych przez ekonomię określających m.in. rentowność funkcjonowania przedsiębiorstw. W takich realiach dochodziło do znaczących rocznych przyrostów zapotrzebowania na moc elektryczną w KSE i tym samym do zmian struktury odbioru. Od połowy dwudziestego wieku, do określania zmienności obciążenia KSE, bazowano na modelach zmienności sezonowej wielkości miesięcznych, wskaźnikach zmienności tygodniowej, scenariuszach rocznego zapotrzebowania na energię (na podstawie [78]). Niektóre z opracowanych w tym czasie wskaźników funkcjonują obecnie lub stanowiły podstawę opracowania innych wskaźników, również z wykorzystaniem metod ekonometrycznych, w tym statystycznych. Jednym z najważniejszych wskaźników obciążenia krajowych systemów elektroenergetycznych jest przebieg obciążenia dla typowych dni roboczych w okresie letnim i zimowym reprezentujący punkt informacyjny dla oczekiwań osiągnięcia największych obciążeń systemów. Analizy tych obciążeń wykorzystywane są zarówno do prognozowania krótkoterminowego jak i do prognozowania wieloletnich zmian zapotrzebowania na moc elektryczną i tym samym planowania rozwoju samego systemu. Obserwacja dobowych przebiegów

zmienności obciążenia KSE pozwala na oszacowanie w różnych horyzontach czasowych, czy przewidywane zmiany będą posiadały charakter stabilny, niezmienny lub słabo zmienny, czy będą charakteryzowały się stosunkowo trwałym ewolucyjnym trendem polegającym np. na spłaszczeniu doliny nocnej lub wypiętrzeniu jednego ze szczytów.

W drugiej dekadzie dwudziestego pierwszego wieku obserwuje się trend spłaszczenia krzywej obciążenia KSE (zmniejszenia różnic w wielkości zapotrzebowania na moc elektryczną) w godzinach nocnych i przyrostów szczytów, szczególnie w okresie letnim wobec obserwowanych zmian klimatycznych. Spłaszczenie obserwowane coraz częściej w godzinach nocnych, które wynika m.in. ze wzrostu udziału odbiorników wentylacyjno – klimatyzacyjnych [214], zróżnicowania ofert taryfowych i zmian przyzwyczajzeń odbiorców, jest przedmiotem analizy w rozprawie w kontekście różnic pomiędzy wartościami prognozowanymi i zrealizowanymi obciążenia KSE. Jednym z czynników wpływających na zmianę kształtu przebiegu dobowego obciążenia KSE w realiach gospodarki rynkowej jest kształtowanie taryf dla grup odbiorców. Taryfy wielostrefowe stanowią element sterowania popytem na energię elektryczną (w tym taryfy dynamiczne). Na kształt krzywej obciążenia KSE wpływają także zmiany przyzwyczajzeń odbiorców [317], [236] wynikające z rosnącej dostępności urządzeń wentylacyjno – klimatyzacyjnych w powiązaniu zarówno z dostępnymi taryfami [210], [211], jak i zaspokajaniem potrzeb, szczególnie komfortu termicznego, wynikającymi ze zmian średniej temperatury otoczenia. Wspomniany komfort termiczny będący funkcją celu zaspokajaną przez odbiorców, w związku ze zmianami temperatury otoczenia i w powiązaniu z długością dnia, w sposób jednoznaczny wpływa na wartości przebiegów dobowych, co wykazano w [78]. Zależność kształtowania obciążenia KSE w powiązaniu z temperaturą otoczenia jest przedmiotem wielu badań na świecie i w Polsce [11], [22], [94], [95], [100], [141], [237], [242], [340], [368], [295]. Długość dnia w kontekście wpływu na zmienność krzywej obciążenia SEE nie jest przedmiotem wielu doniesień literaturowych [368].

1.4. Prognozowanie na tle planowania zapotrzebowania na moc elektryczną w Krajowym Systemie Elektroenergetycznym

Opracowywanie przez Operatora Systemu Elektroenergetycznego, w cyklach dobowych, Planu Koordynacyjnego Dobowego stanowi najważniejszy element planowania rynku bilansującego [230]. Zadanie zapewnienia bezpiecznej pracy KSE powierzone zostało spółce Polskie Sieci Elektroenergetyczne S.A., która pełni rolę OSP, administrując siecią przesyłową w ramach powierzonej roli zarządcy rynku bilansującego [17], [180], [80], [79], [357]. Plany koordynacyjne określają sposób pokrycia zapotrzebowania na moc i energię elektryczną w KSE.

Podstawowym obiektem rynku bilansującego jest jednostka grafikowa definiowana przez miejsce dostarczania energii i związana z jednym uczestnikiem rynku bilansującego [230]. Każda jednostka grafikowa uczestnicząca w sposób aktywny w rynku bilansującym biorąc udział w bilansowaniu systemu oraz zarządzaniu ograniczeniami systemowymi [99], [152], uczestniczy w zadaniu optymalizacyjnym obciążenia podczas tworzenia Planu Koordynacyjnego Dobowego (PKD) oraz Bieżącego Planu

Koordinacyjnego Dobowego (BPKD). Proces optymalizacji obciążenia następuje zgodnie z algorytmem rozdziału obciążeń. Każda jednostka grafikowa, oprócz powyższego zadania, jeżeli nie określono inaczej w Instrukcji Ruchu i Eksploatacji Sieci Przesyłowej [152], musi realizować zadania polegające na [255]: (i) zgłaszaniu do OSP zawartych umów sprzedaży energii, (ii) zgłaszaniu do OSP ofert bilansujących dla jednostek grafikowych aktywnych, (iii) uczestniczeniu w bilansowaniu generacji (za pomocą jednostek grafikowych aktywnych) z zapotrzebowaniem na energię elektryczną w obszarze rynku bilansującego, (iv) uczestniczeniu w działaniach dostosowawczych mających na celu uwzględnienie ograniczeń systemowych, (v) uczestniczeniu w optymalizacji obciążenia zgodnie z algorytmem rozdziału obciążeń podczas tworzenia planów koordynacyjnych dobowych i bieżących planów koordynacyjnych dobowych oraz (vi) uczestniczeniu w rozliczaniu rynku bilansującego w zakresie ofert bilansujących i odchylen od planowanych ilości dostaw energii. Plany PKD i BPKD mają charakter realizacyjny w przeciwieństwie do planów bilansu techniczno – handlowego i wstępnego planu koordynacyjnego dobowego. Planowanie dobowe obejmuje plany bilansu techniczno – handlowego, wstępnego planu koordynacyjnego dobowego, planu PKD i BPKD.

Jednym z wykorzystywanych przez PSE S.A. narzędzi wsparcia procesu decyzyjnego jego jest model LPD [314] bazujący na programowaniu liniowym i rozkładający prognozy zapotrzebowania na moc elektryczną z rozdzielczości godzinowej na rozdzielczość 15 – minutową. Wykorzystanie algorytmu rozdziału obciążeń umożliwia (zapewnia) dobór jednostek wytwórczych centralnie dysponowanych na podstawie danych handlowych i technicznych zgłoszonych w ofertach bilansujących z uwzględnieniem ograniczeń systemowych. Wynikiem działania modelu są informacje umożliwiające opracowanie planu koordynacyjnego dobowego, który określa plan pracy jednostek wytwórczych centralnie dysponowanych na każdą z 24 godzin doby handlowej n . Plan pracy jednostek wytwórczych centralnie dysponowanych uwzględnia zbilansowanie dobowej prognozy zapotrzebowania (na moc i energię elektryczną) i występujące w KSE ograniczenia systemowe, w tym wymagane rezerwy.

Proces zgłaszania danych handlowych i technicznych obowiązuje obiekty typu jednostki grafikowe, operatorów handlowych, operatorów handlowo – technicznych, operatorów systemów rozdzielczych, OSP [230]. Umowy sprzedaży energii zawierają informacje o wolumenie energii sprzedanej i zakupionej dla każdej godziny doby n . Dla każdej godziny doby n określana jest pozycja kontraktowa wyznaczana dla Miejsc Dostarczania dla uczestników rynku bilansującego. Pozycja kontraktowa deklarowana w dobie $n-1$ wynika ze zgłoszeń umów sprzedaży energii, a brak zgłoszenia takiej pozycji skutkuje wyznaczeniem przez OSP pozycji kontraktowej deklarowanej na podstawie danych zawartych w umowie o świadczenie usługi przesyłowej. W odniesieniu do jednostek grafikowych wytwórczych, składane są oferty bilansujące wiążące w sobie umowy sprzedaży energii i techniczne warunki realizacji umów przy zapewnieniu płynnej zmiany wielkości energii elektrycznej wytwarzanej w KSE. Energia deklarowana w ofertach bilansujących posiada formę pasmową, co pozwala na zachowanie elastyczności w powiązaniu umów sprzedaży energii z potencjałem produkcyjnych

uczestniczących jednostek grafikowych wytwórczych. Każda jednostka wytwórcza grafikowa jest zobowiązana dokonać podziału przydzielonych dziesięciu pasm na pasma redukcyjne i pasma przyrostowe. Zadeklarowanie wszystkich dziesięciu pasm jako redukcyjnych skutkuje całkowitym wypełnieniem zawartych umów sprzedaży energii. W przypadku zadeklarowania wszystkich pasm jako przyrostowych dochodzi do zaferowania całej energii na rynku bilansującym (wobec braku zawartych umów sprzedaży energii). Podział pasm pomiędzy pasma redukcyjne i przyrostowe jest dowolny, z punktu widzenia strony wytwórczej i OSP.

Operator Systemu Przesyłowego opracowując plan pracy jednostek wytwórczych grafikowych ustawia wszystkie pasma z otrzymanych ofert w formie stosu w kolejności od najniższej ceny do ceny najwyższej [230]. Przy zachowaniu niezmienności ograniczeń technicznych, dla danej godziny doby OSP, dokonuje porównania stworzonego stosu pasm z prognozowanym zapotrzebowaniem. Ilość energii poniżej punktu przecięcia wielkości zapotrzebowania ze stosem pasm przyjmowana jest do produkcji. W przypadku wzrostu zapotrzebowania powyżej wyznaczonego wcześniej punktu dochodzi do włączenia, przez OSP, do produkcji kolejnych pasm i odwrotnie w sytuacji spadku zapotrzebowania poniżej wcześniej wyznaczonego punktu OSP dokonuje wyłączenia z planu pracy części pasm poprzez redukcję obciążenia w jednostkach grafikowych wytwórczych, które takie pasma wcześniej zgłosiły. Powyższe podejście skutkuje upłynnieniem regulacji wielkości wytwarzania przy zmieniającym się zapotrzebowaniu, a zmniejszony poziom zapotrzebowania skutkuje głównie zmniejszeniem obciążenia jednostki, a nie jej całkowitym wyłączeniem z pracy. Dzięki temu minimalizowane jest u uczestników rynku bilansującego ryzyko, że ich jednostki zostaną wykluczone z możliwości oddawania mocy elektrycznej do sieci. W sytuacji zmniejszania się poziomu zapotrzebowania poniżej wcześniej wyznaczonego optymalnego punktu przecięcia zapotrzebowania ze stosem pasm, dochodzi do optymalizacyjnego wypierania ofert (mocy, energii elektrycznej) redukcyjnych przez oferty przyrostowe. Wspomniana optymalizacja jest skutkiem działania algorytmu rozdziału obciążeń (modelu LPD) i wynika z faktu, że oferty z pasm redukcyjnych są tańsze od ofert przyrostowych. Dane wejściowe do tworzenia planu koordynacyjnego dobowego dzielą się na cztery podstawowe grupy [255]: dane dotyczące potencjału wytwórczego w kontekście zapotrzebowania na moc i energię elektryczną z uwzględnieniem ograniczeń systemowych, dane dotyczące topologii sieci przesyłowej z uwzględnieniem planu wyłączeń elementów sieci, dane zgłaszane przez uczestników rynku w zgłoszeniach ofert bilansujących, dane opisujące jednostki świadczące usługi interwencyjne.

Prognoza zapotrzebowania na moc elektryczną w KSE stanowi jedną z najważniejszych informacji dla OSP (i opracowywanych przez OSP głównie, w oparciu o decyzję ekspercką z wykorzystaniem zbioru dostępnych danych w oparciu o metodę podobieństw przebiegów historycznych analizowanego parametru oraz w oparciu o plany i prognozy parametrów wpływających na pracę KSE). O ile pozostałe parametry stanowią plany, o tyle wyjątkiem od tej reguły jest prognoza zapotrzebowania na moc elektryczną, która jest parametrem niedeterministycznym obciążonym błędem wynikającym z jego stochastycznej natury. Tym samym stanowi element obciążony ryzykiem niedokładnej

jej realizacji (bez uwzględnienia zdarzeń losowych w pracy elementów KSE). W związku z powyższym proces planowania (w ramach opracowywania planów koordynacyjnych dobowych) pracy jednostek grafikowych (ich poziomu wytwarzania) uczestniczących w pokrywaniu zapotrzebowania na moc elektryczną w KSE jest połączony z procesem opracowywania prognozy zapotrzebowania na moc elektryczną (i energię elektryczną). Niedokładność tej prognozy może skutkować występowaniem koniecznością bieżącego bilansowania pracy KSE w celu zapewnienia minimalizacji kosztów pracy KSE (tym samym kosztów wytwarzania jednostek grafikowych) w wyniku działania algorytmu rozdziału obciążeń przy jednoczesnym spełnieniu ograniczeń systemowych. Tym samym punkt styku prognozy zapotrzebowania na moc elektryczną w KSE, jako danej wejściowej obciążonej ryzykiem niedokładnej realizacji, z procesem działania algorytmu rozdziału obciążeń jest elementem, który stanowić może obszar podlegający badaniom umożliwiającym realizację minimalizacji kosztów funkcjonowania KSE. Powyższe spostrzeżenie jest szczególnie istotne w odniesieniu do godzin nocnych funkcjonowania KSE, w których dochodzi do zapewniania rezerw w kontekście realizacji prognozy zapotrzebowania na moc elektryczną w KSE, w szczególności w porównaniu do pozostałych godzin doby. Pomimo minimalizacji błędów prognoz zapotrzebowania na moc elektryczną w godzinach nocnych na przestrzeni lat (począwszy od pierwszego kwartału 2002 roku rozpoczęcia publikacji stosowanych danych przez PSE S.A.) oraz zrównania Cen Rozliczeniowych Odchylenia Sprzedaży i Cen Rozliczeniowych Odchylenia Zakupu na rynku bilansującym, istnieje nadal możliwość optymalizacji procesu opracowywania planów koordynacyjnych dobowych, w szczególności w godzinach nocnych, dzięki poprawie efektywności realizacji prognoz zapotrzebowania na moc elektryczną. W związku z niewielką liczbą nowych metod i modeli prognostycznych testowanych przez PSE S.A., gwarantujących rosnącą skuteczność realizacji prognoz, wydaje się, że obszarem, w którym możliwe jest poszukiwanie nowych skutecznych rozwiązań prognostycznych może być opracowywanie metod autoregresyjnych prognozowania zapotrzebowania na moc elektryczną, ze szczególnym uwzględnieniem zagadnienia prognozowania zapotrzebowania na tę moc w KSE.

Prognozowanie szeregów czasowych, pomimo braku całkowitej pewności ich realizacji, jest zagadnieniem słusznym i utylitarным [319]. Do teoretycznych założeń związanych z możliwością budowania i ekstrapolacji modeli prognostycznych można nieformalnie zaliczyć [319] założenie o właściwym odzwierciedlaniu rzeczywistości przez model prognostyczny i założenie, że rzeczywistość obserwowana dotychczas i w przyszłości pozostanie niezmienna. Dzięki doświadczeniu i wiedzy badacza możliwe jest spełnienie pierwszego założenia. Spełnienie drugiego założenia, w szczególności wobec braku wpływu badacza na przyszłość, jest niemożliwe. Pomimo obciążenia opracowywanych prognoz przedziałem niepewności, wartym zaznaczenia jest fakt, że pozyskanie wiedzy o przewidywanym kształtowaniu się przyszłości pozwala na szybszą reakcję na zachodzące zmiany oraz mniejsze koszty adaptacji do zmiany.

Szeregi czasowe, w swojej naturze, są realizacją pewnego procesu stochastycznego. Proces ten generuje dane, a zadaniem badacza jest zidentyfikowanie czynników charakteryzujących jego własności [319]. W badaniach szeregów czasowych dla potrzeb

prognozowania zakładana jest ich cykliczność, trend, sezonowość i składnik losowy. Cykliczność jest wahaniami odnotowywanych wartości o długim okresie powyżej jednego roku [319]. Trend określany przez zmiany szeregu czasowego w czasie może polegać na systematycznym spadku (trend malejący) lub na systematycznym wzroście (trend rosnący). Sezonowość określana jest jako wahania okresowe o okresie krótszym niż jeden rok. Na składnik losowy składają się czynniki, które nie zostały uwzględnione w modelu ekonometrycznym. Sumowanie wskazanych parametrów skutkuje uzyskaniem modelu addytywnego, natomiast ich mnożenie daje model multiplikatywny. Model addytywny przyjmowany jest do analizy gdy amplituda wahań sezonowych jest stała i niezależna od przeciętnego poziomu zjawiska, natomiast w sytuacji gdy amplituda wahań jest większa w przypadku większej przeciętnej wartości szeregu, a niższa gdy zmienna przyjmuje mniejszą wartość, jako bardziej odpowiedni przyjmowany jest model multiplikatywny. W zagadnieniu prognozowania zjawisk rozpatrywanych w czasie funkcjonują dwie grupy problemów. Pierwsza z nich to prognozowanie tylko na podstawie informacji o dotychczasowej historii zjawiska. W drugiej grupie prognozowanie odbywa się również na podstawie informacji dotyczącej czynników kształtujących poziom prognozowanego zjawiska, czynników towarzyszących i zakłócających [291]. Problemem, przed którym często staje badacz, jest stwierdzenie w jaki sposób określone przyczyny kształtują wybrane przez badacza lub analityka skutki, a brane pod uwagę czynniki nie są od siebie niezależne, lecz nawzajem w różny sposób są od siebie uzależnione. Do metod i technik również wykorzystywanych przez analityków i badaczy można zaliczyć drzewa klasyfikacyjne, metody regresji [90], analizę skupień [350], [290], statystyki opisowe, wizualizację danych [66], reguły połączeń, analizy szeregów czasowych i ciągów zdarzeń, sieci neuronowe [96], [105], [321], [32], maszyny wektorów wspierających, wnioskowanie Bayesowskie, model rozkładu kanonicznego wektora losowego [63], [64], [289], [335], [336]. Do metod z pogranicza metod heurystycznych (wykorzystywanych głównie do optymalizacji) zaliczyć można metodę przeszukiwania Tabu (ang. *Tabu Search* [118]). Prognozy krótkoterminowe przebiegów zapotrzebowania na moc elektryczną w systemach lokalnych mają istotne znaczenie dla krajowego zapotrzebowania na tę moc. Ich uwzględnianie wpływa na całkowite zapotrzebowanie na moc elektryczną w KSE [210], [211], [212], [213].

W niszy zastosowań na etapie budowy modelu prognostycznego jest opracowywanie błędów *ex ante* stanowiące oczekiwane błędy prognozy. Przyczyną takiego stanu jest celowość zastosowań dla szeregów czasowych, dla których oszacowana wartość zmiennej prognozowanej średnio odchyła się od rzeczywistej wartości zmiennej prognozowanej dla kolejnych okresów [357]. Prawidłowo wybrane zmienne objaśniające do liniowego modelu ekonometrycznego powinny charakteryzować się takimi własnościami, jak: duża zmienność, wysoki stopień skorelowania ze zmienną objaśnianą, niski stopień skorelowania z innymi potencjalnymi zmiennymi, które nie znalazły się w zbiorze zmiennych objaśniających [62]. Prognozowanie szeregów czasowych w obszarze elektroenergetyki stanowi jeden z ważniejszych czynników pomagających osobom decyzyjnym w kierowaniu przedsiębiorstwami energetycznymi (zarówno

w sektorze wytwarzania, przesyłu jak i rozdziału), a także w planowaniu [189] zadań i czynności eksploatacyjnych oraz w planowaniu rozwoju KSE. W realiach polskiej elektroenergetyki, prognozowanie przyszłych wartości dotyczy zapotrzebowania na moc elektryczną, moc cieplną, energię elektryczną, energię cieplną, strat energii elektrycznej i cieplnej w przesyśle i dystrybucji, możliwości produkcyjnych różnego rodzaju jednostek wytwórczych pracujących w systemie oraz cen energii elektrycznej.

1.5. Pokrywanie zapotrzebowania na moc elektryczną w systemie elektroenergetycznym

1.5.1. Środki pokrywania zmienności obciążenia dobowego

Środkami służącymi do pokrywania zmieniających się obciążeń w systemach elektroenergetycznych są [242]: (i) sterowanie elektrowniami szczytowo – pompowymi, (ii) zarządzanie planem remontów w sektorze energetyki zawodowej, (iii) wyłączenia ustalonych grup odbiorców, (iv) zarządzanie potencjałem wytwórczym dyspozycyjnym, (v) wymiana mocy z systemami sąsiednimi, (vi) sterowanie turbozespołami dla potrzeb regulacji częstotliwości i mocy. W pierwszym przypadku elektrownie szczytowo – pompowe są przełączane w stan pracy generacyjnej w chwilach osiągnięcia przez SEE szczytów obciążenia, natomiast w chwilach gdy w ciągu doby osiągane są doliny obciążenia następuje ich przejście do stanu pracy pompowej. Środek ten przez wiele lat był stosowany zgodnie z tą regułą do bieżącej regulacji krzywej obciążenia, jednakże w ostatnich latach drugiej dekady dwudziestego wieku przywoływane są do ruchu w trybie interwencyjnym. W drugim przypadku główny nacisk położony jest na planowanie remontów potencjału wytwórczego w energetyce zawodowej na okres letni (obecnie występowanie cieplejszych okresów letnich i dłuższe utrzymywanie się wysokich temperatur w tych okresach – i tym samym zwiększone zużycie wynikające z korzystania z urządzeń klimatyzacyjnych i chłodzących – oraz powiązane z tym występowanie niższych stanów rzek i zbiorników wodnych służących do celów schładzania w procesach wytwarzania w elektrowniach skutkuje krótszymi czasami dostępnymi na remonty i modernizacje majątku wytwórczego). Wyłączanie ustalonych grup odbiorców (trzeci środek) dotyczy w pierwszej kolejności odbiorów przemysłowych. Wyłączanie następuje w sytuacji wystąpienia deficytu energii elektrycznej w danym systemie elektroenergetycznym. Czwarty środek obejmuje zarządzanie grupą turbozespołów, stanowiących wolumen mocy dyspozycyjnej. Zarządzanie polega na ich odstawianiu do rezerwy lub przywołaniu do ruchu ze stanu rezerwy. Piąty środek polega na imporcie i eksporcie energii elektrycznej z systemów elektroenergetycznych krajów stowarzyszonych w europejskiej organizacji ENTSO – E (ang. *European Network of Transmission System Operators for Electricity*). Import zachodzi w przypadku niedoborów energii elektrycznej, natomiast eksport ma miejsce w sytuacjach jej nadmiaru. Szóstym środkiem, który jest jednym z najważniejszych środków regulacji obciążenia SEE, jest wspomaganie regulacji częstotliwości i mocy. Wspomaganie to odbywa się na drodze zmiany obciążenia turbozespołów, które w danej chwili są w ruchu i objęte są układem automatycznej regulacji częstotliwości i mocy [216].

1.5.2. Środki wyrównywania profilu obciążenia dobowego systemu elektroenergetycznego

Oddziaływanie przez energetykę zawodową na wielkość zapotrzebowania na moc i energię elektryczną, w ramach realizacji procesu optymalizacji strategii rozwoju sektora energetycznego, jest możliwe na kilka sposobów. Kompromis osiągnąć jest poprzez równoważenie interesów energetyki zawodowej (m.in. budowa nowych elektrowni, rozwój majątku sieciowego przedsiębiorstw) i potrzeb odbiorców (wraz z możliwościami racjonalizowania ich zużycia energii elektrycznej). Do preferowanych, w sektorze energii elektrycznej, działań w zakresie optymalizacji rozwoju sektora energetycznego, należą [242]: wprowadzanie nowych technologii wytwarzania energii elektrycznej, modernizacja istniejących technologii oraz poprawa sprawności przesyłu i rozdziału energii elektrycznej. Nowe technologie wytwarzania uwzględniają również rozwój wytwarzania energii elektrycznej w skojarzeniu z wytwarzaniem ciepła. Modernizacja istniejących technologii i urządzeń uwzględnia wytyczne dotyczące aspektów ochrony środowiska. Poprawę sprawności przesyłu i rozdziału energii elektrycznej uzyskuje się m.in. poprzez stosowanie przewodów wielowiązkowych w napowietrznych liniach elektroenergetycznych [43], zarządzanie majątkiem sieciowym z uwzględnieniem zagadnień *Predictive Maintenance* [276], wdrażanie nowocześniejszych jednostek transformatorowych [262], stosowanie systemów informatycznych sterowania i nadzoru stacji elektroenergetycznych [324]. W związku z koniecznością zapewniania bezpiecznej pracy KSE o proces zintegrowanego planowania źródeł, i związany z nim proces ekonomicznego pokrywania obciążeń (oraz zobowiązania środowiskowe wynikające z przynależności do Unii Europejskiej), po stronie energetyki zawodowej, dąży się do m.in. optymalizacji budowy nowych elektrowni, optymalizacji wykorzystania majątku stosowanego w sektorze energetycznym oraz do zmniejszenia jednostkowego zużycia paliw. Po stronie odbiorców energii elektrycznej dąży się do optymalizacji użytkowania energii elektrycznej. Dzięki jednoczesnemu optymalizowaniu potrzeb energetyki zawodowej i odbiorców oczekiwany jest rezultat w postaci wyrównywania dobowego profilu obciążenia SEE (zapotrzebowania na moc elektryczną). Wyrównywanie dobowego profilu zapotrzebowania na moc elektryczną polega na zmniejszeniu głębokości (wypełnieniu) dolin (w szczególności doliny nocnej) oraz na zmniejszeniu zapotrzebowania w dobowych szczytach (niwelowanie szczytów). Dodatkową korzyścią wynikającą z wyrównania zmienności zapotrzebowania na moc elektryczną jest jej łatwiejsza regulacja i tym samym niższe koszty funkcjonowania majątku zarządzanego przez przedsiębiorstwo sieciowe. Kształtowanie dobowego profilu zapotrzebowania na moc elektryczną w SEE (wypełnianie dolin i niwelowanie szczytów) w stanie jego normalnej pracy jest możliwe dzięki zastosowaniu m.in. środków tj. [242] środków ekonomicznych, technicznych, organizacyjnych i informacyjnych. Podstawowym środkiem ekonomicznym jest odzwierciedlenie ceny energii w taryfie (nawet płaskiej) według faktycznej ceny produkcji tej energii oraz wprowadzanie zachęt ekonomicznych do korzystania z energii elektrycznej w innych godzinach – na podstawie powyższych kształtowane są taryfy dynamiczne. Cennymi środkami technicznymi dynamicznymi są m.in. sterowanie obciążeniami odbiorców (w tym wyłączenia awaryjne) i sterowanie

urządzeniami oświetleniowymi. Środkiem technicznym długoterminowym jest ukierunkowanie, za pomocą programów społecznych, na instalowanie odbiorników energooszczędnych. Do środków organizacyjnych zalicza się okresy zmiany czasu i właściwe planowanie remontów urządzeń. Najważniejszymi środkami informacyjnymi są programy w zakresie racjonalizacji użytkowania energii elektrycznej i przepisy o funkcjonowaniu gospodarki energetycznej.

1.5.3. Horyzonty prognostyczne

Czynnikami warunkującymi horyzont prognostyczny są: rodzaj wielkości poddawanych analizie, zakres badanych wielkości, przeznaczenie uzyskanych wyników badań (prognoz). W zależności od wymienionych wyżej czynników można wyróżnić następujące zakresy prognozowania [222], [141], [142]:

- **Do 6 godzin:** Skorygowane wartości zapotrzebowania mocy z uwzględnieniem funkcji korelacyjnej procesu zapotrzebowania (funkcji określającej podobieństwo pomiędzy prognozą, a rzeczywistym zapotrzebowaniem na moc elektryczną w systemie elektroenergetycznym). Celem opracowania takiej prognozy jest bieżące sterowanie pracą systemu.
- **Od 6 do 24 godzin:** Wartości zapotrzebowania mocy w poszczególnych godzinach, korygowane są o parametry z prognoz meteorologicznych, wpływu zmian w poborze energii elektrycznej w związku z transmisjami telewizyjnymi, imprezami masowymi oraz innych czynników nieprzypadkowych. Celem opracowania takiej prognozy jest ustalenie programu pracy systemu.
- **Od 1 doby do 3 miesięcy:** Wartości zapotrzebowania mocy w poszczególnych godzinach dla wszystkich dni w analizowanym okresie. Celem opracowania takiej prognozy jest dokonanie korekty planu eksploatacji systemu.
- **Od 3 do 12 miesięcy:** Wartości obciążeń charakterystycznych w poszczególnych dniach okresu. Celem opracowania takiej prognozy jest dokonanie korekty planów remontów, planów produkcji mocy i energii oraz współpracy z zagranicznymi OSP.
- **Od 1 roku do 10 lat:** Miesięczne zapotrzebowanie na energię, średnie i szczytowe wartości miesięczne obciążeń charakterystycznych doby, przebiegi zapotrzebowania mocy dla typowych dób roku. Celem opracowania takiej prognozy jest dokonanie korekty planów inwestycyjnych w źródłach wytwórczych, planowanie inwestycji sieciowych, planowanie wyłączeń na potrzeby remontów i współpracy z zagranicznymi OSP.
- **Od 10 do 15 lat (25 lat):** Krajowe zapotrzebowanie na energię, maksymalne roczne zapotrzebowanie na moc elektryczną, przebieg wykresu uporządkowanego. Celem opracowania takiej prognozy jest planowanie inwestycji w strukturze bazy paliwowo – energetycznej oraz w źródłach energii elektrycznej.

1.5.4. Prognozowanie krótkoterminowe w elektroenergetyce

W przypadku krótkoterminowego prognozowania obciążenia systemów elektroenergetycznych stosuje się od lat zarówno metody autoregresyjne wykorzystujące właściwości średnich kroczących i wygładzania wykładniczego jak i metody wykorzystujące uczenie maszynowe [127], [38], [198], [234], [7], [196], [323], [166] oraz sztuczną inteligencję [320], [166]. Wiele ośrodków naukowych na świecie i w Polsce tworzy coraz dokładniejsze metody i modele prognostyczne w szczególności w kontekście prognozowania krótkoterminowego. W Polsce obszarem prognozowania na potrzeby sektora elektroenergetycznego zajmują się między innymi: Politechnika Częstochowska, Politechnika Wrocławska, Politechnika Warszawska, Instytut Gospodarki Surowcami Mineralnymi i Energią PAN, Akademia Górniczo – Hutnicza, Uniwersytet Ekonomiczny w Krakowie, Politechnika Łódzka, Politechnika Śląska, Uniwersytet Warszawski oraz Szkoła Główna Handlowa w Warszawie. Każdy z tych ośrodków prowadzi badania zarówno na poziomie akademickim, doskonaląc opracowane przez siebie metody i modele, jak i współpracuje z przemysłem. Do przeprowadzanych analiz i symulacji stosowane są m.in. środowiska STATISTICA[®], SAS/ETS, SPSS [20] oraz GRETL [40], [190] oraz języki programowania R i Python. Z pewnością innych ośrodków akademickich, jak i aktywnych przedstawicieli dedykowanego oprogramowania statystycznego jest więcej, jednakże wstępne analizy oraz opracowany przegląd literatury potwierdził, że wspomniane ośrodki naukowe należą do najczęściej publikujących i jednocześnie cytowanych.

Zapotrzebowanie na moc elektryczną w systemie elektroenergetycznym charakteryzuje się dużą fluktuacją [162]. Kluczowymi w tym przypadku są: zmienność dobową, tygodniową, roczną i wieloletnią [242]. Dla potrzeb zobrazowania zmienności zapotrzebowania na moc elektryczną, możliwe jest również wyróżnienie zmienności sezonowej (z której wynika zmienność roczna), zmienności kwartalnej (pory roku) i miesięcznej (części pór roku). Ciągłość zapotrzebowania na moc elektryczną oraz nadal „niewystarczający” (w sensie dużych mocy/pojemności) rozwój magazynów energii, skutkuje brakiem możliwości jej magazynowania w dużych ilościach, co powoduje konieczność bieżącego pokrywania zapotrzebowania na moc elektryczną dokładnie w chwili występowania tego zapotrzebowania [97]. Odzwierciedleniem zmienności zapotrzebowania na moc elektryczną w SEE mogą być ich graficzne reprezentacje pod postacią wykresów obciążenia (zapotrzebowania na moc elektryczną).

Innym czynnikiem, oprócz upływającego czasu (kolejne doby, tygodnie itd.), który wpływa na zmienność obciążenia SEE [75], [76] są m.in. zmienność warunków pogodowych i wynikająca z nich zmienność temperatury otoczenia, a także przechodzenie z czasu zimowego na czas letni [74] i z czasu letniego na czas zimowy (wprowadzone w celu spłaszczenia wieczornego szczytu zapotrzebowania na energię elektryczną w półroczu letnim [242]). Największe wartości zapotrzebowania na moc elektryczną w KSE w szczytach wieczornych występują w miesiącach zimowych (od grudnia do lutego – w grudniu w latach 2004, 2005, 2007, 2009, 2011, 2013; w styczniu w latach 2003, 2006, 2008, 2010, 2012, 2014 – 2016; w lutym w 2012 roku), natomiast najmniejsze najczęściej występują w miesiącach letnich tj. od czerwca

do sierpnia (z wyjątkiem lat 2009, 2011, 2014, gdy nastąpiło to w kwietniu, za wyjątkiem lat 2003 i 2006, gdy nastąpiło to w maju i za wyjątkiem 2016 roku, gdy nastąpiło to w grudniu).

Do innych czynników pogodowych wpływających na poziom zapotrzebowania na moc elektryczną w SEE zaliczyć można m.in. zachmurzenie, wilgotność powietrza i prędkość wiatru [242]. Niemniej jednak to temperatura otoczenia (powietrza/zewnętrzna) w największym stopniu wpływa na obciążenie SEE. Zmiana warunków atmosferycznych wpływa bezpośrednio na zmiany zachowań odbiorców (zarówno komunalnych jak i przemysłowych) polegających na zwiększeniu poboru mocy elektrycznej z urządzeń oświetleniowych i grzewczych (ogrzewanie konwektorowe i ogrzewanie elektryczne).

Poszczególne obszary SEE (Polski i tym samym KSE) posiadają różny udział w kształtowaniu krajowego zapotrzebowania na moc elektryczną. Naturalne jest, że obszary o znacznym uprzemysłowieniu i tym samym znaczącym zaludnieniu w skali kraju przekładają się na większe zapotrzebowanie na moc elektryczną (a w konsekwencji zużycie energii elektrycznej) i tym samym w większym stopniu oddziałuje na te obszary zmiana pogody (warunków atmosferycznych/temperatury otoczenia).

1.5.5. Metody analiz i prognozowania w elektroenergetyce

Klasyczne metody sztucznej inteligencji

Do głównych metod stosowanych w prognozowaniu, optymalizacji, diagnostyce i detekcji oraz projektowaniu w elektroenergetyce stosowane są z powodzeniem trzy główne metody, do których należą: sztuczne sieci neuronowe, algorytmy ewolucyjne i systemy ekspertowe. Sieci neuronowe stosowane są m.in. do [141]: optymalizacji nastawień przełączników zaczepek w transformatorach, optymalizacji nastawień baterii kondensatorów, prognozowania obciążenia szczytowego SEE, obciążeń dobowych SEE [14], [15], [16], [26], [96], [104], [105], [135], [139], [153], [155], [170], [192], [199], [219], [223], [227], [241], [250], [251], [252], [253], [182], [281], [197], [361], [1] analiz zwarciovych, detekcji uszkodzeń transformatorów. Do najczęściej stosowanych metod sztucznej inteligencji [249] w prognozowaniu parametrów pracy systemów i sieci elektroenergetycznych są sieci neuronowe. Sieci neuronowe [321], [356], stanowią skuteczne narzędzie do prognozowania w elektroenergetyce (nie tylko wspomniane obciążenia w sieci elektroenergetycznej [141], [142], [362] ale także ceny energii elektrycznej [42]) szczególnie w prognozowaniu krótkoterminowym [223]. Funkcjonują również w praktycznych zastosowaniach również sieci neuronowe wspomagane technikami logiki rozmytej [84], [89], [272], [273], [351].

Wskazanie większej skuteczności sztucznych sieci neuronowych nad ulepszaniem metod tradycyjnych w prognozowaniu krótkoterminowym obciążeń systemów elektroenergetycznych przedstawione w [95], nie w każdym przypadku posiada przełożenie na krótkoterminowe prognozowanie cen energii na polskich i zagranicznych parkietach obrotu energią elektryczną [47]. W tym kontekście możliwe jest uzyskanie odwrotnej zależności – przykładowo metoda regresji wielorakiej daje znacząco większą efektywność prognozowania w porównaniu do modeli sztucznych sieci neuronowych

[41]. Sztuczne sieci neuronowe wykazują wysoką skuteczność nie tylko w prognozowaniu krótkoterminowym, ale również długoterminowym [92], [138].

Algorytmy ewolucyjne stosowane są m.in. do [141]: prognozowania obciążeń dobowych SEE [16], [170], optymalizacji konfiguracji sieci elektroenergetycznych, optymalizacji poziomów napięć w sieciach elektroenergetycznych, projektowania sieci elektroenergetycznych, planowania pracy elektrowni, ekonomicznego rozdziału obciążeń na poszczególne zespoły, planowania rozwoju SEE, wspomaganie wykonywania czynności regulacyjnych w SEE, automatyce zabezpieczeniowej [263], [353]. Systemy ekspertowe mają zastosowanie m.in. w [141]: projektowaniu sieci i stacji elektroenergetycznych, odbudowy SEE w stanach poawaryjnych.

Dodatkowe informacje na temat zastosowań metod sztucznej inteligencji z uwzględnieniem badanej tematyki zmienności obciążeń SEE oraz jej prognozowania można znaleźć w pozycjach: [18], [141], [249], [333], [374].

Metody Data Mining

W literaturze koncentrującej się na analizie dużych zbiorów danych i prognozowaniu z wykorzystaniem metod *Data Mining* funkcjonuje wiele definicji tych metod i idei [375].

Główne definicje *Data Mining* to:

- interdyscyplinarne podejście wykorzystujące techniki z nauczania maszyn, rozpoznawania obrazów, statystyki, baz danych oraz wizualizacji w celu wydobywania informacji z dużych baz danych [135], [27], [308];
- analiza zazwyczaj dużych, wcześniej zgromadzonych zbiorów danych w celu odkrycia nowych prawidłowości i opisanie danych w nowy sposób, który jest zrozumiały i użyteczny dla właściciela danych [131].

Pierwsza z definicji pochodzi z 1998 roku, natomiast druga z 2001 roku, tym samym zauważalna jest ich ewolucja.

Kolejne definicje Metod *Data Mining* to:

- proces poszukiwania wartościowych informacji (wiedzy) w sytuacji, gdy badacz ma do czynienia z dużą ilością danych [165], [207], [348], [343];
- proces badania i analizy dużych ilości danych metodami automatycznymi lub półautomatycznymi w celu odkrycia znaczących wzorców i reguł [68], [311];
- metody szeroko rozumianej analizy danych mających na celu identyfikację nieznaną wcześniej prawidłowości występujących w dużych zbiorach danych, a powstałe wyniki mają mieć postać łatwą do interpretacji przez prowadzącego badania [206].

Metodom *Data Mining*, w początkach ich rozwoju, zarzucano nienaukowość, bezzałożeniowość, brak teorii, brak elegancji, brak dowodów formalnych, prymitywizm, nastawienie tylko na zastosowania [288].

W klasycznym podejściu do analizy danych stosowany jest schemat [268], [310] od zdefiniowania problemu, przez stworzenie modelu matematycznego, przygotowanie danych wejściowych, analizę zagadnienia do interpretacji uzyskanych wyników. W podejściu *Data Mining* stosowany jest schemat od zdefiniowania problemu, przez

przygotowanie danych wejściowych, analizę zagadnienia, stworzenie modelu matematycznego do interpretacji uzyskanych wyników. Algorytmy stosowane w dziedzinie *Data Mining* dzielone są na metody z nauczycielem i bez nauczyciela [375]. W metodach z nauczycielem głównym celem jest odtworzenie wartości badanego parametru, natomiast w metodach bez nauczyciela, ze względu na brak wyróżnienia pojedynczej cechy, dąży się do wykrycia struktur lub ukrytych wzorców w analizowanych danych. Uczenie modeli prognostycznych z nauczycielem może odbywać się jako realizacja zagadnienia klasyfikacyjnego lub regresyjnego. W zagadnieniach klasyfikacyjnych analizowany parametr ma charakter jakościowy, a w zagadnieniach regresyjnych parametr ten ma charakter ilościowy.

Wiedza pochodząca z badań empirycznych jest sprawdzona i wobec gromadzenia coraz większych zbiorów danych korzystne dla dalszych badań, zarówno empirycznych jak i prognostycznych (w pewnym sensie spekulatywnych), za użyteczne należy uznać analizę tych zbiorów i wyciąganie dodatkowych wniosków. Wynikiem dodatkowych badań, w tym eksperymentalnych, może być uzyskanie większej liczby odpowiedzi, niż postawionych przez badacza pytań [303], [322], [301]. Wskazana w [303] klasyfikacja typów zagadnień i właściwych dla nich metod *Data Mining* w odniesieniu do analizy szeregów czasowych mówi o uwzględnieniu sieci neuronowych typu MLP (ang. *MultiLayer Perceptron*) i RBF (ang. *Radial Basis Function*) w tym zbiorze metod. Należy wnioskować tym samym, że klasyfikacje metod przenikają się i nie funkcjonują jako hermetyczne.

Grupa metod i modeli *Data Mining* obejmuje również zagadnienia prognostyczne, które podzielone są na dwie grupy. Do pierwszej grupy należą drzewa regresyjne i klasyfikacyjne, a do drugiej metody zaawansowanego uczenia maszyn. Drzewa klasyfikacyjne i regresyjne obejmują drzewa C&RT (ang. *Classification And Regression Trees*) i drzewa CHAID (ang. *Chi – Square Automatic Interaction Detection*) [208], [307]. Na grupę zaawansowanego uczenia maszyn składają się metody *MARSplines* (ang. *Multivariate Adaptive Regression Splines*), SVM (ang. *Support Vector Machines*), k najbliższych sąsiadów (ang. *k Nearest Neighbours*) [87] [309], k – średnich (ang. *k – Means*) [341], [302], naiwny klasyfikator Bayesa (ang. *Naive Bayes Classifier*) stosowany wyłącznie do zagadnień klasyfikacyjnych, losowy las (ang. *Random Forest*) [157] i drzewa ze wzmacnianiem (ang. *Boosted Trees*) [208], [306]. Wykorzystywanie metod *Data Mining* w zagadnieniach prognostycznych regresyjnych polega głównie na testowaniu wielu modeli, porównywaniu ich wyników skuteczności oraz tworzeniu układów hybrydowych, dzięki którym możliwe jest zachowanie najmniejszych odchyłeń wartości prognozowanych od zrealizowanych wartości analizowanych parametrów. Cechą wyróżniającą metody *Data Mining* jest szybkość ich tworzenia. Do najskuteczniejszych modeli predykcyjnych z grupy metod *Data Mining*, dla potrzeb prognozowania zapotrzebowania na moc elektryczną w systemach elektroenergetycznych, zaliczyć należy metodę *MARSplines* i *Boosted Trees*.

Metoda *MARSplines* znajduje się w niszy praktycznych zastosowań w zagadnieniach prognozowania w elektroenergetyce wielkoskalowej. W metodzie *MARSplines*, typu nieparametrycznego zaliczającej się do grupy metod uczenia z nauczycielem,

wykorzystuje się współzmiennosc cech do przewidywania wartości wybranej cechy – oraz w zagadnieniach klasyfikacyjnych [136], [209]. Zaletą grupy metod nieparametrycznych jest brak konieczności przyjmowania założeń dotyczących postaci funkcji opisującej analizowane zjawisko, zmiennych objaśniających kształtujących zjawisko i zależności pomiędzy zmiennymi objaśniającymi [209]. Wskazana dogodność wyklucza z czynności badawczych konieczność analizy korelacji pomiędzy zmiennymi niezależnymi, które w wielu przypadkach mogą korelować z prognozowaną zmienną, jednakże nie wywierają na nią wpływu.

Metoda *MARSplines* (wielozmienna regresja adaptacyjna [244], [304], [13]) wykorzystuje metodę rekurencyjnego podziału przestrzeni cech do budowy modelu regresyjnego w postaci krzywych składanych (sklejanych) [110], [107], [108], [109] i stanowi rozwinięcie metod drzew regresyjnych i regresji wielorakiej [12]. Dzięki powyższym właściwościom metoda *MARSplines* [110], [108], [109] jest skutecznym narzędziem do zastosowań dla dużych zbiorów danych [12], [67]. Metoda *MARSplines* umożliwia również automatyczny dobór zmiennych objaśniających do modeli prognostycznych. Efektywność tego doboru jest w wielu przypadkach większa niż dla klasycznych metod doboru zmiennych [48], [52], [58], [44], [49]. Tym samym metoda może być z powodzeniem stosowana, podobnie jak metoda, regresji wielorakiej w zagadnieniu doboru zmiennych wejściowych do modeli prognostycznych jak i do prognozowania krótkoterminowego szeregów czasowych, w tym zapotrzebowania na moc elektryczną w systemach elektroenergetycznych [56], [50], [51].

Alternatywną metodą, wobec metod analizujących w procesie prognostycznym korelacje między zmiennymi objaśniającymi jest metoda głównych składowych. Umożliwia ona nie tylko usunięcie zmiennych nadmiernie ze sobą skorelowanych, ale także otrzymanie nieskorelowanych zmiennych, które odpowiadają za część zmienności grup zmiennych lub nawet za zmienność całych grup zmiennych [243]. Zastosowanie metody tworzy nowe zmienne, które są liniowymi kombinacjami pierwotnych zmiennych i kolejne składowe mają za zadanie ujmować jak najwięcej informacji zawartych w oryginalnych danych. Wadą metody jest trudność interpretacji znaczenia składowych głównych [243].

Big Data

Big Data to termin określający, na dużym poziomie ogólności, bardzo duże zbiory danych. Zbiory te charakteryzują się zróżnicowaną strukturą o dużej złożoności. Główne trudności dotyczą przechowywania danych, analiz w czasie rzeczywistym oraz wizualizacji danych i wyników analiz [275], [6]. Proces badania ogromnych ilości danych, w celu ujawnienia ukrytych wzorców i tajnych korelacji, nazywany jest analizą dużych zbiorów danych. W latach 90 – tych dwudziestego wieku i w pierwszej dekadzie dwudziestego pierwszego wieku analizy *Big Data* kryły się pod pojęciem *Data Mining*. Zbiory *Big Data* charakteryzują się: dużą objętością (ang. *Volume*) [352], [6], [364], [265], dużą szybkością narastania (ang. *Velocity*) [352], [6], [364], [265] wiarygodnością i dokładnością (ang. *Veracity*) [275], [6], dużą różnorodnością (ang. *Variety*) [364], [265] i wartością dla procesów podejmowania decyzji (ang. *Value*) [339], [6], [364], [265].

Zastosowanie analizy zbiorów *Big Data* dla potrzeb zbiorów danych zawierających pomiary elektryczne, w tym wielkość obciążenia systemów elektroenergetycznych,

obejmuje praktyczne zastosowania m.in. technik tj. analiza korelacji i techniki uczenia maszynowego (w tym uczenie głębokie [337], [280], [82], [133], [338], [117], [34], [139], [175], [337] oraz bazy danych [134]). Przetwarzanie danych pomiarowych elektrycznych obejmuje przetwarzanie rozproszone (przechowywanie i przetwarzanie danych – ang. *Distributed Computing*), przetwarzanie pamięciowe (odczyt i przetwarzanie danych – ang. *Memory Computing*) i przetwarzanie strumieniowe (przetwarzanie danych w czasie rzeczywistym – ang. *Stream Processing*) [6], [373].

Stosowanie technik *Big Data* w systemach elektroenergetycznych przyczynia się do wspierania zrównoważonego rozwoju sektora elektroenergetycznego [148], [159], [161] i rozwoju sieci typu *Smart* [373], [193], [39], [203], [82], [7]. Oprócz zastosowań dla potrzeb prognozowania techniki tego typu stosowane są w integracji nowych klasycznych źródeł wytwarzania [292], w szczególności źródeł odnawialnych [187], [366] oraz w tworzeniu zapasowych zbiorów danych, które mogą być wykorzystywane w sytuacjach zakłóceń komunikacji teleinformatycznej [200].

Stosowanie zbiorów, technik i przetwarzania w odniesieniu *Big Data* dla potrzeb elektroenergetyki nierozłącznie powiązane jest z bezpieczeństwem przechowywanych danych. Bezpieczeństwo danych tego typu można zwiększać poprzez ich rozproszenie lokalizacyjne (np. system SCOOP) [364].

Strumienie danych zasilających zbiory *Big Data* w przesyłowych i dystrybucyjnych systemach elektroenergetycznych pochodzą z [279], [202], [281], [248]: systemów SCADA (ang. *Supervisory Control And Data Acquisition*) [150], układów pomiaru fazonów w technologii WAMS (ang. *Wide Area Management System*) [156], z układów IED (ang. *Intelligent Electronic Device*), z systemów zarządzania majątkiem sieciowym, z liczników konwencjonalnych i typu *Smart* [359], [128], [332], [280] z systemów wymiany informacji z uczestnikami rynku energii elektrycznej, z instytutów sejsmicznych i meteorologicznych, z systemów GPS (ang. *Global Positioning System*), z systemów GIS (ang. *Geographic Information System*). Stosowana w praktyce metoda podobieństwa dni [85], [86], [91], [233], [197] pozwala na osiągnięcie jakości prognozowania zapotrzebowania na moc elektryczną poniżej 3,00% w ciągu doby, a w odniesieniu do skuteczności uzyskiwanej przez PSE S.A. ok. 1,00%. W pierwszym kroku wybierane są podobne dni wobec najświeższych prognoz czynników wpływających na zapotrzebowanie. W drugim kroku obliczana jest średnia ważona dla każdej godziny doby z uwzględnieniem historycznych wartości. W klasycznym podejściu stosuje się niewielkie zróżnicowanie w wartościach poszczególnych wag. Dzięki zastosowaniu zwiększania wag dla dni najbardziej podobnych możliwe jest uzyskanie błędów minimalnych, maksymalnych i średnich dla całej doby poniżej 2% [233]. Metoda samoadaptacyjnego ważenia z powodzeniem stosowana jest w prognozowaniu zapotrzebowania na moc elektryczną w mikrosieciach. Na tle metod standardowych dynamicznych profili zapotrzebowania, regresji wielorakiej i sieci neuronowych daje prawie dwukrotną poprawę skuteczności prognozowania (ok. 3,5%) [167]. Podobny poziom skuteczności (3,99%) z zastosowaniem metody regresji wielorakiej dla systemu elektroenergetycznego wskazuje, że pomimo dłuższego czasu obliczeń (dla horyzontu siedmiu dób), jej klasyczna wersja [274], wykorzystująca jako

dane wejściowe (zmiennie objaśniające) prognozy parametrów pogodowych, daje podobną jakość. Zastosowanie sztucznych sieci neuronowych w krótkoterminowym prognozowaniu zapotrzebowania na moc elektryczną w systemach elektroenergetycznych nie zawsze daje wyjątkowo skuteczne wyniki prognoz w porównaniu do innych metod. Stosowanie sztucznych sieci neuronowych wymaga znaczącego doświadczenia badacza, a wyniki, nawet z zastosowaniem wydajnych metod nauki sieci [280], rzadko dają skuteczność poniżej 1,00% w skali doby. Często zaawansowane sieci neuronowe dają efektywność prognozowania wyrażoną wartościami błędów MAPE na poziomie od ok. 3,00% do nawet ok. 13,00% (w horyzoncie 20 dni) [196]. Wiedza o parametrach jakości energii elektrycznej jest jednym z kluczowych elementów podmiotów funkcjonujących na rynku [331]. Cykliczne pomiary tych parametrów (w tym ocena stanu aparatów i urządzeń elektrycznych [149]), ich przesył i gromadzenie oraz prowadzone analizy mogą wpływać na średnioterminowe planowanie wyłączeń poszczególnych elementów sieci przesyłowej i tym samym pośrednio na krótkoterminowe prognozowanie zapotrzebowania na energię elektryczną.

2. Stan badań w obszarze prognozowania zapotrzebowania na moc elektryczną w systemie elektroenergetyczny

Przegląd bibliografii przedstawiony w Tabeli 2.1 obejmuje 47 unikatowych pozycji i tytułów literaturowych, kilkadziesiąt metod prognozowania oraz 264 modele prognostyczne. Publikacje uwzględnione we wspomnianej tabeli zostały opublikowane w okresie od 1997 roku do 2018 roku dotyczą krótkoterminowego prognozowania zapotrzebowania na moc elektryczną. Dane źródłowe, stanowiące wsad do modeli prognostycznych, obejmowały okres od 1998 roku do 2014 roku. Zróżnicowane i międzynarodowe zespoły autorskie przeprowadziły swoje badania bazując na danych o funkcjonowaniu systemów elektroenergetycznych 25 krajów zlokalizowanych na 4 Kontynentach – w krajach Bliskiego i Dalekiego Wschodu, Europy Zachodniej (w tym Wysp Brytyjskich) i Centralnej (w tym Polski) oraz Ameryki Północnej (USA) i Australii. Wskazane publikacje opracowano w 44 zróżnicowanych zespołach autorskich i opublikowano w 23 wydawnictwach. Przeprowadzona analiza dotycząca nazewnictwa modeli prognostycznych obejmuje zbiór składający się ze 185 unikatowych pozycji. Zróżnicowanie odnotowanych zależności w poszczególnych modelach prognostycznych skutkuje wyodrębnieniem 197 unikatowych skrótów przypisanych modelom prognostycznym.

Wszystkie zgromadzone pozycje literaturowe zaprezentowane w Tabeli 2.1 do opisu skuteczności analizowanych modeli prognostycznych wykorzystywały również miernik oceny jakości prognoz MAPE. W celu ułatwienia przeprowadzenia analizy zgromadzonych wyników prognoz wyodrębniono 27 unikatowych nazw błędów MAPE odzwierciedlających wykorzystane w analizach modele prognostyczne. Część wyników prognoz opisanych wskaźnikiem MAPE, zawartych w wytypowanych publikacjach, prezentowana jest w formie przedziału od wartości najmniejszej (MAPE min) do wartości największej (MAPE max), natomiast pozostała część wyników opisana jest jedną wartością.

Analiza wyników jednowartościowych została sztucznie rozłożona na wartości minimalne i maksymalne w celu ujednoczenia dominującego podejścia zastosowanego w wytypowanych publikacjach. Najmniejsze wartości dla kategorii (kolumny) MAPE min odnotowuje się w przedziale od 0,01% do 21,18%, podczas gdy w kategorii (kolumnie) MAPE max odpowiedni przedział zmienności błędów MAPE kształtuje się w zakresie od 0,01% do 33,45%. Kategoria MAPE min obejmuje 196 unikatowych pozycji ze zbioru 264 modeli, natomiast do kategorii MAPE max zalicza się łącznie 212 unikatowych pozycji, z tego samego zbioru całkowitego.

Dalsza analiza wyników skuteczności uzyskanych prognoz opisywanych miernikiem jakości prognozowania za pomocą błędu MAPE dotyczy kategorii MAPE min. W kategorii tej wytypowano zbiór 10 najmniejszych wyników wyrażonych wartościami procentowymi (Rys 2.3.1.). Zbiorowi temu nadano nazwę Top 10. W zestawieniu tym znajdują się modele metod prognostycznych z grup zbiorów rozmytych, (RR, ANFIS, RR, LR), sztucznych sieci neuronowych (SSN), regresji ogólnej (MRO, MROP, RR)

i rankingowania modeli prognostycznych (DEA). Najmniejsze wartości błędów MAPE min, w kolejności rosnącej, w zbiorze Top 10 (Rys. 2.3.1) uzyskuje się kolejno dla modeli: DEA, RR, MRO, AG, ANFIS, SSN, MROP, SSN(F), SSN, LR. Wartości błędów MAPE min opisywane są odpowiednio wartościami: 0,01%; 0,08%; 0,10%; 0,14%; 0,15%; 0,16%; 0,20%; 0,27%; 0,28% i 0,29%. Zbiórcze zestawienie skrótów zastosowanych dla metod i modeli prognostycznych w zbiorze Top 10 zamieszczono poniżej, natomiast pełny wykaz skrótów zamieszczono w Tabeli 2.1: DEA – *Data Envelopment Analysis*; RR – regresja rozmyta; MRO – model regresji ogólnej; AG – algorytm genetyczny; ANFIS – *Adaptive Neuro Fuzzy Inference System*; SSN – sztuczna sieć neuronowa; MROP – model pełny regresji ogólnej; SSN – sztuczna sieć neuronowa falkowa; LR – logika rozmyta.

Jedynie badania analityczne dotyczące modelu prognostycznego MRO wykonane są w trybie *ex ante*. W przypadku tego modelu uzyskaną efektywność prognozowania w trybie wyprzedzającym na pozycji trzeciej należy uznać za bardzo wysoką. Model MRO wykorzystuje jako zmienną wejściową informację o kształtowaniu temperatury otoczenia. Drugim modelem wykorzystującym zmienne wejściowe jest model MROP, który uwzględnia zarówno informację o zmienności temperatury otoczenia jak i prędkości wiatru. Model MROP plasuje się na siódmej pozycji w zestawieniu Top 10 w kategorii MAPE min.

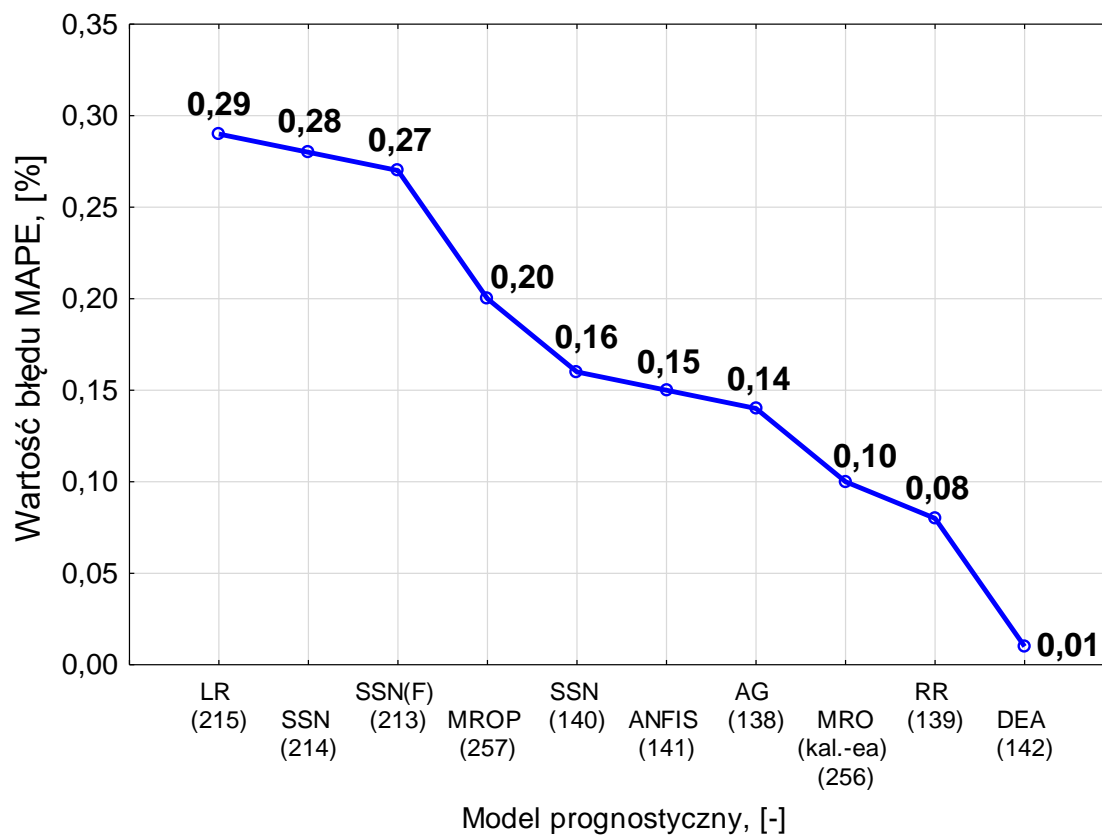
Pełne nazwy modeli prognostycznych w zestawieniu Top 10 przedstawiają się następująco: *Data Envelopment Analysis*, regresja rozmyta, regresja ogólna z wykorzystaniem informacji o temperaturze otoczenia, algorytm genetyczny (AG – ang. *Genetic Algorithm* – GA), *Adaptive Neuro Fuzzy Inference System* [296], [295], sztuczna sieć neuronowa, regresja ogólna pełna z wykorzystaniem informacji o temperaturze otoczenia i prędkości wiatru, Sztuczna sieć neuronowa falkowa (przetestowana na systemie australijskim), Sztuczna sieć neuronowa (analizowana dla systemu australijskiego), Logika rozmyta (zastosowana dla systemu australijskiego).

Wszystkie pozycje literaturowe w zestawieniu Top 10 opublikowano w wydawnictwie Elsevier. Skuteczność prognostyczna opisywana najmniejszą wartością błędu MAPE min w sposób niejednoznaczny wpływa na wysoką efektywność prognozowania. Tym samym przegląd literatury przedmiotu nie powinien opierać się na długości tytułu publikacji. Wszystkie publikacje zakwalifikowane do zbioru Top 10 opracowane są przez zespoły autorskie składające się z co najmniej 2 osób. Systemami elektroenergetycznymi poddanymi analizom prognostycznym w zestawieniu Top 10 są (w kolejności narastającej) systemy Iranu (2 pozycje), USA (1 pozycja), Iranu (3 pozycje), USA (1 pozycja), Australii (3 pozycje).

Długość analizowanego okresu analizy w znaczący sposób wpływa na uzyskiwaną jakość prognozowania. Wraz z wydłużeniem okresu analizy, obejmującego w sposób naturalny wpływ dni wolnych od pracy i świąt, zarówno cyklicznych jak i niecyklicznych, dochodzi do regresji skuteczności uzyskiwanych prognoz obciążenia systemów elektroenergetycznych.

Przedostatnia kolumna Tabeli 2.1 w zawiera autorską rekomendację dotyczącą potencjału analizowanych metod w kontekście potrzeb PSE S.A.

Publikacje [114], [115] i [330] z lat 2019 – 2021 wskazują, że kontynuowane są analizy i badania m.in. z wykorzystaniem części metod wskazanych w Tabeli 2.1.



Rys. 2.1. Skuteczność prognozowania modeli progностycznych w zbiorze Top 10 z grupy 264 modeli.

Źródło: Opracowanie własne na podstawie Tabeli 2.1.

Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej

Tab. 2.1. Stan badań.

Lp.	Autor/Tytuł/Wydawnictwo	Rok	Zakres analizy	Kraj	Metoda, model	Skuteczność <i>ex post</i>			Numer modelu	Rekom.	Poz. lit.	
		[-]	[lata]	[-]	[-]	Typ błędu, [%]			[-]	Tak/Nie	[-]	
1.	Al-Fuhaid A.S. et al. <i>Neuro-Short-Term Load Forecast of the Power System in Kuwait</i> Elsevier (21:215-219)	1997	1994	Kuwejt	SSN(ea) – Sztuczna sieć neuronowa	MAPE(ea)	1,84	4,84	1	TAK	[2]	
2.	Almeshhaiei E., Soltan H. <i>A Methodology for Electric Power Load Forecasting</i> Alexandria Engineering Journal (50)	2011	2006 – 2008	Kuwejt	MA(ea7,30) – Średnia krocząca (7, 30)	MAPE(ea)	3,84		2	TAK	[3]	
3.	Al-Shobaki S., Mohsen M. <i>Modeling and Forecasting of Electrical Power Demands for Capacity Planning</i> Elsevier Energy Conversion and Management (49)	2008	2002 – 2007	Jordania	ARIMA(ea)	MAPE(ea)	5,25		3	TAK	[5]	
4.	Badran S.M., Abouelatta O.B. <i>Forecasting Electrical Load using ANN Combined with Multiple Regression Method</i> The Research Bulletin of Jordan ACM II(II)	2013	1988 – 2006	Arabia Saudyjska	RW – Regresja wieloraka	MAPE	11,58	14,35	4	Nie	[9]	
5.	Brodowski S. et al. <i>A Hybrid System for Forecasting 24-h Power Load Profile for Polish Electric Grid</i> Elsevier B.V. Applied Soft Computing (58)	2017	2013, 2015	Polska (KSE)	AH+RW – AH – Aproksymator hierarchiczny + RW - regresja wieloraka	MAPE	1,08	2,26	6	TAK	[24]	
6.	Buitrago J., Asfour S. <i>Short-Term Forecasting of Electric Loads Using Nonlinear Autoregressive Artificial Neural Networks with Exogenous Vector Inputs</i> Energies 10(40)	2017	2005 – 2015	USA (New England)	SSN – Sztuczna sieć neuronowa	MAPE	0,85		7	TAK	[26]	
7.	Ceperic E., Ceperic V. <i>A Strategy for Short-Term Load Forecasting by Support Vector Regression Machines</i> IEEE Transactions on Power Systems (1)	2013	2006	USA	SSN – Sztuczna sieć neuronowa	MAPE	1,50	3,72	8	TAK	[28]	
					SDBWNN – Similar Day – Based Wavelet Neural Network	MAPE	1,26	2,70		9		TAK
					SASVR – Seasonality – Adjusted, Support Vector Regression	MAPE	0,93	1,86		10		TAK
8.	Chahkoutahi F., Khashei M. <i>A Seasonal Direct Optimal Hybrid Model of Computational Intelligence and Soft Computing Techniques for Electricity Load Forecasting</i> Energy (140)	2017	2011.05.02 – 2011.07.03	Australia	ARIMA	MAPE	0,76	1,07	11	TAK	[30]	
					SSN(MLP) – Sztuczna sieć neuronowa (Perceptron wielowarstwowy)	MAPE	0,72	1,23		12		TAK
					ANFIS – Adaptive Neuro Fuzzy Inference System	MAPE	0,83	0,95		13		TAK
					DOPH – Direct Optimum Parallel Hybrid	MAPE	0,58	0,71		14		TAK

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 2.1. Ciąg dalszy.

9.	Chapagain K., Kittipiyakul S.	2016	2013 – 2015	Tajlandia	RW – Regresja wieloraka	MAPE	1,75	33,45	15	Nie	[31]
	<i>Short-Term Electricity Load Forecasting Model and Bayesian Estimation for Thailand Data</i>				RW(Gibbs) – Regresja wieloraka (Próbkowanie Gibbsa)	MAPE	0,85	23,06	16	Nie	
	MATEC Web of Conferences (55)										
10.	Chen H. et al.	2001	1999	Kanada	SSN – Sztuczna sieć neuronowa	MAPE	0,48	3,00	17	TAK	[32]
	<i>ANN-Based Short-Term Load Forecasting in Electricity Markets</i>										
11.	Chheepa T.K., Manglani T.	2017	1996 – 1997, 2000	Iran	ARIMA	MAPE	1,48	1,99	18	TAK	[33]
	<i>A Critical Review on Employed Techniques for Short Term Load Forecasting</i>										
12.	Clements A.A. et al.	2015	1999.07.12 – 2013.11.27	Australia	ARIMA	MAPE	1,36	2,89	19	TAK	[37]
	<i>Forecasting Day-Ahead Electricity Load Using a Multiple Equation Time Series Approach</i>										
13.	Czapaj R., Rzepka P., Szablicki M.	2016	2010 – 2014	Polska (KSE)	MARSplines	MAPE	1,86	6,99	20	TAK	[58]
	<i>Typowanie zmiennych objaśniających przy wykorzystaniu zautomatyzowanych metod statystycznych jako sposób optymalizacji wyboru metody estymacji szczytowego dobowego obciążenia KSE</i>				C&RT – Ogólne modele drzew klasyfikacyjnych i regresyjnych	MAPE	2,57	7,18	21	TAK	
	Przegląd Elektrotechniczny 4(93)				C&RT – Ogólne modele drzew klasyfikacyjnych i regresyjnych	MAPE	2,56	6,77	22	TAK	
					Chi ² – Automatyczny detektor interakcji za pomocą chi – kwadrat	MAPE	4,06	7,33	23	TAK	
					CHAID – Chi – Square Automatic Interaction Detector	MAPE	3,69	9,40	24	TAK	
14.	Czapaj R., Kamiński J., Benalcazar P.	2018	2009 – 2014	Polska (KSE)	MARSplines	MAPE	1,86	6,99	25	TAK	[44]
	<i>Dobór zmiennych objaśniających z wykorzystaniem metody MARSplines</i>										
15.	Czapaj R., Kamiński J., Benalcazar P.	2018	2009 – 2014	Polska (KSE)	MARSplines	MAPE	3,36	6,04	26	TAK	[49]
	<i>Prognozowanie krótkoterminowe z wykorzystaniem metody MARSplines</i>				MARSplines(ea)	MAPE(ea)	6,57	27			
16.	Dąsal K.	2002	1993 – 1995	Polska (KSE)	MRK(pn-pt) – Metoda Rozkładu Wektora Kanonicznego	MAPE(pn-pt)	0,64	9,79	28	TAK	[50]
	<i>Dobór zmiennych wejściowych do Modelu Rozkładu Kanonicznego</i>										

Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej

Tab. 2.1. Ciąg dalszy.

17.	Dudek G.	2010	2002 – 2006	Polska (KSE)	SFS(5 lat) – <i>Sequential Forward Selection Methods</i>	MAPE	1,84	29	TAK	[63]	
	<i>Short-Term Load Forecasting Based on Kernel Conditional Density Estimation</i>				SBS(5 lat) – <i>Sequential Backward Selection Methods</i>	MAPE	1,77	30	TAK		
					NS(5 lat) – Najbliższych sąsiadów	MAPE	1,94	31	TAK		
					SSN(5 lat) – Sztuczna sieć neuronowa	MAPE	2,02	32	TAK		
					FE(5 lat) – <i>Fuzzy Estimators</i>	MAPE	1,76	33	TAK		
			SFS(4 lata) – <i>Sequential Forward Selection Methods</i>	MAPE	2,19	34	TAK				
	Przegląd Elektrotechniczny 8(86)		1997 – 2000	Polska (KSE)	SBS(4 lata) – <i>Sequential Backward Selection Methods</i>	MAPE	2,06	35	TAK	[88]	
					NS(4 lata) – najbliższych sąsiadów	MAPE	2,55	36	TAK		
					SSN(4 lata) – Sztuczna sieć neuronowa	MAPE	2,24	37	TAK		
					FE(4 lata) – <i>Fuzzy Estimators</i>	MAPE	2,14	38	TAK		
18.	Dudek G., Janicki M.	2017	2011 – 2014	Polska (KSE)	NSWPR(robocze) – Najbliższych sąsiadów z wejściami pogodowymi dla analizy podobieństw	MAPE(robocze)	1,55	1,67	39	TAK	[94], [95]
				Belgia		MAPE(robocze)	2,82	2,88	40	TAK	
				Nowa Anglia		MAPE(robocze)	2,41	3,26	41	TAK	
				USA		MAPE(robocze)	3,43	4,82	42	TAK	
	<i>Nearest Neighbour Model with Weather Inputs for Pattern-based Electricity Demand Forecasting</i>		2011 – 2014	Polska (KSE)	NSWPW(weekendy) – Najbliższych sąsiadów z wejściami pogodowymi dla analizy podobieństw	MAPE(weekendy)	1,75	1,76	43	TAK	
				Belgia		MAPE(weekendy)	3,02	3,12	44	TAK	
				Nowa Anglia		MAPE(weekendy)	2,92	3,16	45	TAK	
				USA		MAPE(weekendy)	4,31	4,99	46	TAK	
	Przegląd Elektrotechniczny 3(93)		2011 – 2014	Polska (KSE)	NSWPS(Święta) – Najbliższych sąsiadów z wejściami pogodowymi dla analizy podobieństw	MAPE(Święta)	4,36	16,17	47	TAK	
				Belgia		MAPE(Święta)	4,05	12,61	48	TAK	
				Nowa Anglia		MAPE(Święta)	6,35	7,03	49	TAK	

Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej

19.	Dudek G.	2016	2002 – 2004	USA	MAPE(Swięta)	6,05	7,62	50	TAK	[93]
				RW(sty.) – Regresja wieloraka	MAPE(sty.)	2,37	51	TAK		
RK(sty.) – Regresja krokowa	MAPE(sty.)	1,52	52							
RG(sty.) – Regresja grzbietowa	MAPE(sty.)	1,59	53							
Lasso(sty.) – Regresja najmniejszej bezwzględnej selekcji i operatora zawężania	MAPE(sty.)	1,51	54							
RSG(sty.) – Regresja składowych głównych	MAPE(sty.)	1,36	55							
RCNK(sty.) – Regresja cząstkowych najmniejszych kwadratów	MAPE(sty.)	1,18	56							
RW(lip.) – Regresja wieloraka	MAPE(lip.)	2,63	57	TAK						
RK(lip.) – Regresja krokowa	MAPE(lip.)	1,14	58	TAK						
RG(lip.) – Regresja grzbietowa	MAPE(lip.)	1,23	59	TAK						
Lasso(lip.) – (Regresja najmniejszej bezwzględnej selekcji i operatora zawężania)	MAPE(lip.)	1,06	60	TAK						
RSG(lip.) – Regresja składowych głównych	MAPE(lip.)	0,94	61	TAK						
RCNK(lip.) – Regresja cząstkowych najmniejszych kwadratów	MAPE(lip.)	1,00	62	TAK						
Pattern-Based Local Linear Regression Models for Short-Term Load Forecasting	2016	2002 – 2004	Polska (KSE)	RSG – Regresja składowych głównych	MAPE	1,35	63	TAK		
				RCNK – Regresja cząstkowych najmniejszych kwadratów	MAPE	1,34	64			
				ARIMA	MAPE	1,82	65			
				WW – Wygładzanie wykładnicze	MAPE	1,66	66			
				SSN(MLP) – Sztuczna sieć neuronowa (Perceptron wielowarstwowy)	MAPE	1,44	67			
				ENW – Estymator Nadaraya – Watson	MAPE	1,30	38			
				MN – Metoda naiwna	MAPE	3,43	39			
				2007 – 2009	Francja	RSG – Regresja składowych głównych	MAPE	1,71	70	TAK
						RCNK – Regresja cząstkowych najmniejszych kwadratów	MAPE	1,57	71	
						ARIMA	MAPE	2,32	72	
						WW – Wygładzanie wykładnicze	MAPE	2,10	73	
						SSN(MLP) – Sztuczna sieć neuronowa (Perceptron wielowarstwowy)	MAPE	1,64	74	
						ENW – Estymator Nadaraya – Watson	MAPE	1,66	75	
						MN – Metoda naiwna	MAPE	5,05	76	

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Elsevier, Electric Power System Research (130)	2007 – 2009	Wielka Brytania	RSG – Regresja składowych głównych	MAPE	1,60	77	TAK				
			RCNK – Regresja cząstkowych najmniejszych kwadratów	MAPE	1,54	78					
			ARIMA	MAPE	2,02	79					
			WW – Wygładzanie wykładnicze	MAPE	1,85	80					
			SSN(MLP) – Sztuczna sieć neuronowa (Perceptron wielowarstwowy)	MAPE	1,65	81					
			ENW – Estymator Nadaraya – Watson	MAPE	1,55	82					
			MN – Metoda naiwna	MAPE	3,52	83					
	2006 – 2008	Australia	RSG – Regresja składowych głównych	MAPE	3,00	84	TAK				
			RCNK – Regresja cząstkowych najmniejszych kwadratów	MAPE	2,83	85					
			ARIMA	MAPE	3,67	86					
			WW – Wygładzanie wykładnicze	MAPE	3,52	87					
			SSN(MLP) – Sztuczna sieć neuronowa (Perceptron wielowarstwowy)	MAPE	2,92	88					
			ENW – Estymator Nadaraya – Watson	MAPE	2,82	89					
			MN – Metoda naiwna	MAPE	4,88	90					
20.	2016	2002 – 2004	Polska (KSE)	LL(sty.) – Losowy las	MAPE(sty.)	1,42	91	TAK			
				C&RT(sty.) – Drzewa klasyfikacyjne i regresyjne	MAPE(sty.)	1,70	92	TAK			
				C&RTR(sty.) – Drzewa klasyfikacyjne i regresyjne rozmyte	MAPE(sty.)	1,62	93	TAK			
				ARIMA(sty.)	MAPE(sty.)	2,64	94	TAK			
				WW(sty.) – Wygładzanie wykładnicze	MAPE(sty.)	2,35	95	TAK			
				SSN(sty.) – Sztuczna sieć neuronowa	MAPE(sty.)	1,32	96	TAK			
				MN(sty.) – Metoda naiwna	MAPE(sty.)	6,37	97	Nie			
				LL(lip.) – Losowy las	MAPE(lip.)	0,92	98	TAK			
				C&RT(lip.) – Drzewa klasyfikacyjne i regresyjne	MAPE(lip.)	1,16	99	TAK			
				C&RTR(lip.) – Drzewa klasyfikacyjne i regresyjne rozmyte	MAPE(lip.)	1,13	100	TAK			
				ARIMA(lip.)	MAPE(lip.)	1,21	101	TAK			
				WW(lip.) – Wygładzanie wykładnicze	MAPE(lip.)	1,19	102	TAK			
				SSN(lip.) – Sztuczna sieć neuronowa	MAPE(lip.)	0,97	103	TAK			
				MN(lip.) – Metoda naiwna	MAPE(lip.)	1,29	104	Nie			
21.	2015	2009	Turcja	SSN – Sztuczna sieć neuronowa	MAPE	3,67	105	TAK			
				MF+SSN – MF – Metoda falkowa + SSN – Sztuczna sieć neuronowa	MAPE	3,73	106	TAK			
				MF+SSN(RBF) – MF – Metoda falkowa + SSN – Sztuczna sieć neuronowa (Radialne funkcje bazowe)	MAPE	2,89	107	TAK			
				DE – Dekompozycja empiryczna	MAPE	3,52	108	TAK			
		2010		SSN – Sztuczna sieć neuronowa	MAPE	3,81	109	TAK			
				MF+SSN – MF – Metoda falkowa + SSN – Sztuczna sieć neuronowa	MAPE	4,18	110	TAK			
				Dudek G.							
				Politechnika Częstochowska							

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

	Turkish Journal of Electrical Engineering & Computer Sciences (23)				MF+SSN(RBF) – MF – Metoda falkowa + SSN – Sztuczna sieć neuronowa (Radialne funkcje bazowe)	MAPE	2,99	111	TAK		
					DE – Dekompozycja empiryczna	MAPE	3,63	112	TAK		
22.	Fan S.	2010	1997 – 2009 (uczący) 2009.01.01 – 2009.01.31 (testowy)	Australia	PMA – Półparametryczny model addytywny	MAPE	1,41	2,37	113	TAK	[103]
	<i>Short-Term Load Forecasting Based on a Semi-Parametric Additive Model</i>				SSN – Sztuczna sieć neuronowa	MAPE	1,82	3,90	114		
	IEEE Transactions On Power Systems				PMA+SSN – Model hybrydowy	MAPE	1,58	2,79	115		
23.	Farahat M.A.	2018	2011.07.01 – 2011.08.10 (uczący) 2011.08.11 – 2011.08.17 (testowy)	Egipt	SSN(BP) – Sztuczna sieć neuronowa (Uczenie-propagacja wsteczna – <i>Back Propagation</i>)	MAPE	4,60		116	TAK	[104]
	<i>Short Term Load Forecasting Using Neural Networks and Particle Swarm Optimization</i>				SSN(BP)+PSO – SSN(BP) – Sztuczna sieć neuronowa (Uczenie – propagacja wsteczna – <i>Back Propagation</i>) + PSO – optymalizacja rojem cząstek	MAPE	1,90		117	TAK	
	Journal of Electrical Engineering										
24.	Gorwar M.	2012	2011 – 2012	Indie	AR(ea) – Autoregresja	MAPE	13,03		118	Nie	[121]
	<i>Short Term Load Forecasting Using Time Series Analysis: A Case Study for Karnataka, India</i>				ARMA(ea)	MAPE	11,73		119	Nie	
	ResearchGate, IJESIT Conference				ARIMA(ea)	MAPE	6,15		120	Nie	
25.	Hassan S., Khosravi A., Jaafar J.	2015	2011 (interwały 30-min)	Malezja, Australia, Pakistan	SSN(I) – Sztuczna sieć neuronowa (integracyjna)	MAPE(I 30 min.)	7,16		121	TAK	[135]
	<i>Examining Performance of Aggregation Algorithms for Neural Network-Based Electricity Demand Forecasting</i>				SSN(IP) – Sztuczna sieć neuronowa (integracyjna przycinana)	MAPE(I 30 min.)	10,13		122	TAK	
					SSN(UB) – Sztuczna sieć neuronowa (uśrednianie Bayesowskie)	MAPE(I 30 min.)	4,34		123	TAK	
	ScienceDirect, Electrical Power and Energy Systems (64)				MN – Metoda naiwna	MAPE(I 30 min.)	6,41		124	TAK	
26.	He W.	2014	2000.02.10 – 2012.11.30	Chiny	SSN – Sztuczna sieć neuronowa	MAPE	1,90	2,08	125	TAK	[139]
	<i>Deep Neural Network Based Load Forecast</i>										
	Computer Modelling & New Technologies 18(3)										
27.	Hong T., Wang P.	2014	2005 – 2007	USA	RRBI(ea) – Regresja rozmyta bez interakcji	MAPE(ea)	14,21		126	TAK	[146]
	<i>Fuzzy Interaction Regression for Short Term Load Forecasting</i>				RRBIZJ(ea) – Regresja rozmyta bez interakcji ze zmiennymi jakościowymi	MAPE(ea)	5,16		127	TAK	
					RRBI(ea)+RW – RRBI(ea) – Regresja rozmyta bez interakcji + RW – Regresja wieloraka	MAPE(ea)	4,63		128	TAK	
					RRBI(ea)+ZT – RRBI(ea) – Regresja rozmyta bez interakcji + ZT – zmienne temperaturowe	MAPE(ea)	3,68		129	TAK	
	University of North Carolina at Charlotte 13(1)										
28.	Janicki M.	2017	2013 – 2014	USA	PO+KT(USA 2013) – PO – Podobieństwa obrazów + Korekcja temperaturowa (USA 2013)	MAPE	4,50		130	TAK	[154]
				USA	MN(USA 2013) – Metoda naiwna (USA 2013)	MAPE	10,78		131	Nie	

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

	<i>Temperature Correction Method for Pattern Similarity-Based Short-term Electricity Demand Forecasting Models</i>			USA	PO+KT(USA 2014) – PO – Podobieństwa obrazów + KT – Korekcja temperaturowa (USA 2014)	MAPE	4,86	132	TAK		
				USA	MN(USA 2014) – Metoda naiwna (USA 2014)	MAPE	10,94	133	Nie		
				Belgia	PO+KT(BEL 2013) – PO – Podobieństwa obrazów + KT – Korekcja temperaturowa (Belgia 2013)	MAPE	3,80	134	TAK		
				Belgia	MN (BEL 2013) – Metoda naiwna (Belgia 2013)	MAPE	8,54	135	Nie		
				Belgia	PO+KT(BEL 2014) – PO – Podobieństwa obrazów + KT – Korekcja temperaturowa (Belgia 2014)	MAPE	3,66	136	TAK		
				Belgia	MN(BEL 2014) – Metoda naiwna (Belgia 2014)	MAPE	9,47	137	Nie		
29.	Kheirkhah A. et al. <i>Improved Estimation of Electricity Demand Function by Using of Artificial Neural Network, Principal Component Analysis and Data Envelopment Analysis</i> Elsevier Ltd. Computers & Industrial Engineering (64)	2013	1992.04.01 – 2003.02.28	Iran, Irlandia, Turcja	AG – Algorytm Genetyczny	MAPE	0,14	138	TAK	[170]	
					RR – Regresja rozmyta	MAPE	0,08	139	TAK		
					SSN – Sztuczna sieć neuronowa	MAPE	0,16	140	TAK		
					ANFIS – Adaptive Neuro Fuzzy Inference System	MAPE	0,15	141	TAK		
					DEA – Data Envelopment Analysis	MAPE	0,01	142	TAK		
30.	Kolcun M., Holka L. <i>Daily Load Diagram Prediction of Eastern Slovakia</i> Politechnika Częstochowska, VI Konferencja PE	2002	1997 – 1998	Słowacja	SSN(Koh)	MAPE	3,50	143	TAK	[174]	
					– Sztuczna sieć neuronowa Kohonena						
31.	Lin Y. <i>An Ensemble Model Based on Machine Learning Methods and Data Preprocessing for Short-Term Electric Load Forecasting</i> Energies 10(1186)	2017	2010.08.01 – 2011.07.31	Australia	EML – Extreme Machine Learning	MAPE	0,83	144	TAK	[198]	
					EMLDE – Extreme Machine Learning (optimized by) Differential Evolution	MAPE	0,77	145	TAK		
					ARIMA	MAPE	0,73	146	TAK		
					EMLWTMABC – Tranformata falkowa – Wavelet Transform – Modified Artificial Bee Colony – Extreme Machine Learning	MAPE	0,59	147	TAK		
					EMLMDDE – Empirical Mode Decomposition – Differential Evolution – Extreme Machine Learning	MAPE	0,39	148	TAK		
					VMD – Variational Mode Decomposition	MAPE	0,30	149	TAK		
32.	Liu N., Babushkin V., Afshari A. <i>Short-Term Forecasting of Temperature Driven Electricity Load Using Time Series and Neural Network Model</i> Journal of Clean Energy Technologies 2(4)	2014	2010.01.01 – 2011.06.30	Zjednoczone Emiraty Arabskie	SARIMAX	MAPE	1,58	150	TAK	[199]	
					SSN – Sztuczna sieć neuronowa	MAPE	2,29	151	TAK		
33.	Magnano L., Boland J.W. <i>Generation of Synthetic Sequences of Electricity Demand: Application in South Australia</i> Elsevier Ltd. Energy (32)	2006	2000 – 2001 (okres letni)	Australia	ARMA(lato)	MAPE (lato)	2,40	152	TAK	[218]	
34.	Nadtoka I.I., Al-Zihery B.M.	2015	2009 – 2012	Irak	SVM+PSO – SVM – Metoda wektorów nośnych + PSO – optymalizacja rojem	2011.05.11.	MAPE(UV; maj 2011)	2,65	153	TAK	[234]
					2011.08.31.	MAPE(UV; sie. 2011)	1,23	154			

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

	<i>Mathematical Modelling and Short-Term Forecasting of Electricity Consumption of the Power System, with Due Account of Air Temperature and Natural Illumination, Based on Support Vector machine and Particle Swarm</i>				cząstek (z uwzględnieniem wyłącznie promieniowania słonecznego)	2011.11.30.	MAPE(UV; lis. 2011)	2,13	155	TAK	
						2012.01.26.	MAPE(UV; sty. 2012)	1,73	156		
					SVM+PSO – SVM – Metoda wektorów nośnych + PSO – optymalizacja rojem cząstek (z uwzględnieniem wyłącznie temperatury otoczenia)	2011.05.11.	MAPE(Temp.; maj 2011)	2,60	157		
						2011.08.31.	MAPE(Temp.; sie. 2011)	1,37	158		
						2011.11.30.	MAPE(Temp.; lis. 2011)	1,94	159		
	Elsevier Ltd. Procedia Engineering (129)				SVM+PSO – SVM – Metoda wektorów nośnych + PSO – optymalizacja rojem cząstek (z uwzględnieniem promieniowania słonecznego i temperatury otoczenia)	2012.01.26.	MAPE(Temp.; sty. 2012)	1,90	160		
						2011.05.11.	MAPE(UV; Temp.; maj 2011)	2,26	161		
						2011.08.31.	MAPE(UV; Temp.; sie. 2011)	1,41	162		
						2011.11.30.	MAPE(UV; Temp.; lis. 2011)	1,61	163		
	35.	Narayan A.	2017	2006 – 2016	Kanada	SSN(sty.) – Sztuczna sieć neuronowa	MAPE (sty.)	4,60	165	TAK	
ARIMA(maj)						MAPE (maj)	5,70	166			
SSN-LSTM-RNN(wrz.) – Long – Short – Term Memories – Recurrent Neural Network						MAPE (wrz.)	4,40	167			
<i>Long Short Term Memory Networks for Short-Term Electric Load Forecasting</i>		IEEE International Conference on Systems, Man, and Cybernetics				SSN(sty.) – Sztuczna sieć neuronowa	MAPE (sty.)	6,30	168	TAK	
						ARIMA(maj)	MAPE (maj)	8,20	169		
						SSN – LSTM – RNN(wrz.) – Long – Short – Term Memories – Recurrent Neural Network	MAPE (wrz.)	5,90	170		
						SSN(sty.) – Sztuczna sieć neuronowa	MAPE (sty.)	3,80	171	TAK	
						ARIMA(maj)	MAPE (maj)	3,90	172		
						SSN-LSTM-RNN(wrz.) – Long – Short – Term Memories – Recurrent Neural Network	MAPE (wrz.)	3,80	173		
36.		Nowicka-Zagrajek J., Weron R.				2002	1999.01.01 – 2000.12.31	USA	ARMA(1,6) (1 sty. – 28 lut.)	MAPE	1,66
	<i>Modeling Electricity Loads in California: ARMA Models with Hyperbolic Noise</i>	ARMA Adaptacyjny (3 sty. – 28 lut.)	MAPE	1,66	175						
		Hugo Steinhaus Center Wrocław University of Technology, KBN	ARMA(1,6) (1 sty. – 28 lut.)	MAPE	1,24				176	TAK	
			ARMA Adaptacyjny (3 sty. – 28 lut.)	MAPE	1,23				177		
37.	Nowotarski J. et al.	2015	2007.01.01 – 2011.12.31	USA	Proste(ea)	MAPE(ea)	2,10	2,82	178	TAK	
					TA(PU – ea) (Przycinanie uśredniane)	MAPE(ea)	2,10	2,82	179	TAK	
					WA(UW – ea) (Uśrednianie Winsora)	MAPE(ea)	2,10	2,83	180	TAK	
					OLS(MNKea) (MNK zwyczajna)	MAPE(ea)	2,14	2,82	181	TAK	
					LAD(ea)	MAPE(ea)	2,14	2,83	182	TAK	
					(Regresja min. odchylenia bezwzględnego)						

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

38.	Improving Short Term Load Forecast Accuracy via Combining Sister Forecasts	2009	2002 – 2007	Tajwan	PW(ea) (MNK ograniczona – dodatnie wagi)	MAPE(ea)	2,12	2,81	183	TAK	[147]
					CLS(ea) (MNK ograniczona)	MAPE(ea)	2,11	2,83	184	TAK	
					IRMSE(ea) uśredniana	MAPE(ea)	2,10	2,82	185	TAK	
					BI – C(ea) (Najlepsze indywidualne okno kalibracyjne)	MAPE(ea)	2,25	2,93	186	TAK	
					Model siostrzany 1(ea)	MAPE(ea)	2,29	3,09	187	TAK	
					Model siostrzany 2(ea)	MAPE(ea)	2,24	3,15	188	TAK	
	Hugo Steinhaus Center Wrocław University of Technology, University of North Carolina at Charlotte				Model siostrzany 3(ea)	MAPE(ea)	2,34	3,01	189	TAK	
					Model siostrzany 4(ea)	MAPE(ea)	2,32	3,17	190	TAK	
					Model siostrzany 5(ea)	MAPE(ea)	2,28	3,11	191	TAK	
					Model siostrzany 6(ea)	MAPE(ea)	2,30	3,18	192	TAK	
					Model siostrzany 7(ea)	MAPE(ea)	2,37	3,07	193	TAK	
					Model siostrzany 8(ea)	MAPE(ea)	2,31	3,21	194	TAK	
39.	Pao H.-T.	2009	2002 – 2007	Tajwan	ECSTSP – Modelowanie przestrzenne z korekcją błędu (<i>Error – Correction State Space Model</i>)	2002-2007	MAPE	3,90	195	TAK	[147]
						2003-2007		2,57	196		
						2004-2007		2,38	197		
						2005-2007		1,52	198		
						2006-2007		2,57	199		
						2007		2,04	200		
	Forecast of Electricity Consumption and Economic Growth in Taiwan by State Space Modeling			Tajwan	STSP – Modelowanie przestrzenne bez korekcji błędu (<i>State Space Model</i>)	2002-2007	MAPE	4,04	201	TAK	
						2003-2007		2,62	202		
						2004-2007		2,43	203		
						2005-2007		1,75	204		
						2006-2007		2,34	205		
						2007		2,39	206		
	Elsevier Ltd. Energy (34)			Tajwan	SARIMA	2002-2007	MAPE	5,32	207	TAK	
						2003-2007		3,79	208		
						2004-2007		3,01	209		
						2005-2007		2,87	210		
						2006-2007		2,18	211		
						2007		1,20	212		
Rana M, Koprinska I.	Australia	2016	2006 – 2007	SSN(F – Aus.) - Sztuczna sieć neuronowa falkowa	MAPE	0,27	213	TAK	[267]		
				SSN(Aus.) – Sztuczna sieć neuronowa	MAPE	0,28	214	TAK			
				LR(Aus.) – Logika rozmyta	MAPE	0,29	215	TAK			
				MTR(Aus.) – Model Tree Rules	MAPE	0,35	216	TAK			
				WW(n-1; Aus.) – Wygładzanie wykładnicze - Sezonowość dobową	MAPE	0,30	217	TAK			
				WW(n -7; Aus.) – Wygładzanie wykładnicze - Sezonowość tygodniową	MAPE	0,32	218	TAK			
				WW(n -1 i n -7; Aus.) – Wygładzanie wykładnicze - Sezonowość dobową i tygodniową	MAPE	0,30	219	TAK			
				ARIMA(n -1; Aus.) dobową	MAPE	0,30	220	TAK			
				ARIMA(n -7; Aus.) tygodniową	MAPE	0,32	221	TAK			
ARIMA(n -1 i n -7; Aus.) dobową i tygodniową	MAPE	0,30	222	TAK							

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

	<i>Forecasting Electricity Load with Advanced Wavelet Neural Networks</i>		2010 – 2011	Australia	MP(Aus.) – Model przemysłowy	MAPE	0,31	223	TAK	
				Australia	MNU(Aus.) – Metoda naiwna uśredniona	MAPE	13,48	224	Nie	
				Australia	MNO(Aus.) – Metoda naiwna opóźniona	MAPE	0,47	225	TAK	
				Australia	MN(n -1; Aus.) – Metoda naiwna (poprzednia doba)	MAPE	5,05	226	TAK	
				Australia	MN(n -7; Aus.) – Metoda naiwna (poprzedni tydzień)	MAPE	4,94	227	TAK	
				Hiszpania	SSN(F – Hisz.) – Sztuczna sieć neuronowa falkowa	MAPE	1,72	228	TAK	
				Hiszpania	SSN(Hisz.) – Sztuczna sieć neuronowa	MAPE	2,12	229	TAK	
				Hiszpania	LR(Hisz.) – Logika rozmyta	MAPE	2,25	230	TAK	
				Hiszpania	MTR(Hisz.) – Model Tree Rules	MAPE	2,24	231	TAK	
				Hiszpania	WW(n -1; Hisz.) – Wygładzanie wykładnicze – Sezonowość dobową	MAPE	2,54	232	TAK	
	Hiszpania	WW(n -7; Hisz.) – Wygładzanie wykładnicze – Sezonowość tygodniową	MAPE	2,01	233	TAK				
	Hiszpania	WW(n -1 i n -7; Hisz.) – Wygładzanie wykładnicze – Sezonowość dobową i tygodniową	MAPE	1,95	234	TAK				
	Hiszpania	ARIMA(n -1; Hisz.) dobową	MAPE	2,45	235	TAK				
	Hiszpania	ARIMA(n -7; Hisz.) tygodniową	MAPE	2,00	236	TAK				
	Hiszpania	ARIMA(n -1 i n -7; Hisz.) dobową i tygodniową	MAPE	1,89	237	TAK				
	Hiszpania	MP(Hisz.) – Model przemysłowy	MAPE	0,31	238	TAK				
	Hiszpania	MNU(Hisz.) – Metoda naiwna uśredniona	MAPE	21,18	239	Nie				
	Hiszpania	MNO(Hisz.) – Metoda naiwna opóźniona	MAPE	5,05	240	TAK				
	Hiszpania	MN(n -1; Hisz.) – Metoda naiwna (poprzednia doba)	MAPE	9,45	241	TAK				
	Hiszpania	MN(D-7; Hisz.) – Metoda naiwna (poprzedni tydzień)	MAPE	7,42	242	TAK				
40.	Siwek K., Osowski S.	2009	2006 – 2008	Polska (KSE)	SSN(MLP) – Sztuczna sieć neuronowa (Perceptron wielowarstwowy)	MAPE	2,07	243	TAK	[281]
	SSN(SVM) – Sztuczna sieć neuronowa (Metoda wektorów nośnych)				MAPE	2,24	244	TAK		
	SSN(Elman) – Sztuczna sieć neuronowa (Elman)				MAPE	2,26	245	TAK		
	SSN(SO) – Sztuczna sieć neuronowa (SO)				MAPE	2,37	246	TAK		
	SSN(MLPZ1) – Sztuczna sieć neuronowa (zespół – Perceptron wielowarstwowy 1)				MAPE	1,48	247	TAK		
	SSN(SVMZ) – Sztuczna sieć neuronowa (zespół – Metoda wektorów nośnych)				MAPE	1,35	248	TAK		
	SSN(BSSZ) – Sztuczna sieć neuronowa (zespół – BSS)				MAPE	1,71	249	TAK		
	<i>Prognozowanie obciążeń 24-godzinnych w systemie elektroenergetycznym z użyciem zespołu sieci neuronowych</i>									
	Przegląd Elektrotechniczny 8(85)									

Tab. 2.1. Ciąg dalszy.

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

41.	Selivan R.A., Rajagopal R. <i>A Model For The Effect of Aggregation on Short Term Load Forecasting</i> IEEE, Stanford University	2014	-	USA	ARMA	MAPE	2,00	250	TAK	[278]	
	SVR (Regresja wektorów nośnych)				MAPE	4,00	251	TAK			
	SSN(FF) – Sztuczna sieć neuronowa (Uczenie-Fast Forward)				MAPE	2,40	252	TAK			
42.	Sousa J.C., Neves LP., Jorge H.M. <i>Assessing the Relevance of Load Profiling Information in Electrical Load Forecasting Based on Neural Network Models</i> Elsevier Ltd. Electrical Power and Energy Systems (40)	2012	2006.12.15 – 2009.11.30	Portugalia	SSN(OK) – Sztuczna sieć neuronowa (odbiorcy komunalni)	MAPE	6,13	22,39	253	TAK	[293]
	SSN(GPZ) – Sztuczna sieć neuronowa (stacja transformatorowa spółki dystrybucyjnej)				MAPE	5,14	5,35	254	TAK		
43.	Wang P., Liu B., Hong T. <i>Electric Load Forecasting with Recency Effect: A Big Data Approach</i> Hugo Steinhaus Center Wrocław University of Technology	2015	2007	USA	MFN – Metoda efektu niedawności (prognozy dla każdej doby z rocznym wyprzedzeniem)	MAPE	4,27	4,38	255	TAK	[336]
	44.				Wang Y., Bielecki J.M. <i>Acclimation and the Response of Hourly Electricity Loads to Meteorological Variables</i> Elsevier Ltd. Energy (142)	2018	1999.07.28. – 2007.12.31. (zestaw kalibracyjny)	USA	MRO(Temp.) – Model regresji ogólnej (temperaturowy)	MAPE(Temp.)	~0,10
		MROP(ea; Temp.; Wiatr) – Model pełny regresji ogólnej (opóźnienia godzinowe termosensytywności, zmienne binarne historycznych temperatur w miesiącach, prędkość wiatru)	MAPE(ea; Temp.; Wiatr)	~0,20	~4,30				257		
		2008.01.01. – 2014.12.31.	MRO2K(Temp.; Wiatr; Wilg.) – Model 2-krokowy regresji ogólnej (1. – dopasowanie do modelu pełnego; 2. – dopasowanie do modelu wpływu wilgotności na zapotrzebowanie)	MAPE(Temp.; Wiatr; Wilg.)	1,00				2,00	258	TAK
45.	Wyrozumski T. <i>Prognozowanie neuronowe w energetyce</i> Politechnika Lubelska, Konferencja REE	2005	-	Polska	SSN(ea) – Sztuczna sieć neuronowa	MAPE(ea)	1,31	4,87	259	TAK	[361]
46.	Yang J. <i>Power System Short-term Load Forecasting</i> TU Darmstadt, Rozprawa doktorska	2006	2002	Chiny	C&RT – Drzewa klasyfikacyjne i regresyjne	MAPE	2,63	11,64	260	TAK	[363]
	SSN – Sztuczna sieć neuronowa				MAPE	1,51	4,13	261	TAK		
	SVM – Metoda Wektorów nośnych				MAPE	1,51	3,87	262	TAK		
47.	Yu X., Ji H. <i>A PSO-SVM-Based 24 Hours Power Load Forecasting Model</i> MATEC Web of Conferences (25)	2015	2014	Chiny	SSN(BP) – Sztuczna sieć neuronowa (Uczenie – wsteczna propagacja – <i>Back Propagation</i>)	MAPE	3,28	4,13	263	TAK	[365]
	SVM+PSO – SVM – Metoda wektorów nośnych + PSO – Optymalizacja rojem cząstek				MAPE	2,58	2,68	264	TAK		

3. Opracowanie modelu matematycznego do prognozowania zapotrzebowania na moc elektryczną wykorzystującego metodę ważonych współczynników funkcji autokorelacji cząstkowej

3.1. Zarys teoretyczny

Modele autoregresyjne stosuje się w badaniach statystycznych, ekonometrii oraz m.in. w przetwarzaniu sygnałów. Modele tego typu odzwierciedlają procesy losowe zachodzące w zróżnicowanych środowiskach, zarówno przyrodniczych jak i ekonomicznych. Autoregresyjna natura zjawisk wskazuje, że zmienna wyjściowa (inne nazwy to zmienna zależna, zmienna objaśniana, zmienna celu [346]) jest uzależniona liniowo od swoich wcześniejszych (historycznych) wartości oraz od czynnika stochastycznego. W związku z powyższym modele autoregresyjne mają postać równań różnicowych. Wzbogacenie modelu autoregresyjnego o część średniej kroczącej tworzy model autoregresyjny ze średnią kroczącą i w dalszej części modyfikacji model zintegrowany ze średnią kroczącą. Analiza szeregów czasowych w znacznej mierze bazuje na stacjonarności danych jednak w większości przypadków założenie, że badany szereg jest niestacjonarny jest zbyt proste [25]. Modele autoregresyjne nie zawsze mają charakter stacjonarny, natomiast modele średniej kroczącej zawsze posiadają taki charakter. Występowanie wartości odstających w szeregach czasowych w sposób znaczący wpływa na ich kształtowanie i efektywność późniejszego prognozowania.

Część autoregresyjna definiowana jest za pomocą funkcji autokorelacji i umożliwia obliczenie współczynników autoregresji. Współczynniki autoregresji szacowane mogą być na wiele sposobów. Do dwóch najczęściej stosowanych jest zwykła procedura najmniejszych kwadratów błędów lub metoda momentów wykorzystująca równania Yule – Walker’a [21]. W przypadku metody momentów podstawowe równanie modelu autoregresji wyższego rzędu, dzięki bezpośredniej zgodności (odpowiedniości) podstawowych parametrów modelu i jego rzędu z funkcją kowariancji [168], możliwe jest jej odwrócenie co pozwala na określenie parametrów z funkcji autokorelacji. Zabieg ten jest wykonalny ze względu na fakt, że funkcja autokorelacji otrzymywana jest z funkcji kowariancji. Cała operacja odbywa się za pomocą równań Yule – Walker’a [367], [334], [323] których alternatywną wersję dla funkcji autokorelacji cząstkowej, oprócz metody inwersji bezpośredniej, przedstawiono w niniejszym rozdziale.

Obliczenia wartości współczynników funkcji autokorelacji cząstkowej wykonano w środowisku STATISTICA[®], który wykorzystuje metodę inwersji i równań Yule – Walker’a. Analizy wykonane zostały na podstawie przesłanek metodycznych sformułowanych w [11], [41], [66], [67], [68], [183], [191], [208], [209], [243], [319], [286], [287], [288], [289], [290], [291], [297], [298], [299], [300], [301], [302], [303], [304], [305], [306], [307], [308], [309], [310], [311], [312], [322], [343], [344], [345],

[346], [347], [375]. Były one wspomagane wykorzystaniem pakietu MS Excel® bazując na przesłankach opublikowanych w [266], [271].

W fundamentalnej postaci równań Yule – Walker’a wykorzystywana jest funkcja autokowariancji oraz funkcja delta Kroneckera. Obliczanie parametrów modelu autoregresyjnego z wykorzystaniem równań Yule – Walker’a, poprzez zastępowanie teoretycznych wartości współczynników kowariancji ich estymowanymi wartościami, możliwe jest na trzy sposoby [102], jako:

- estymację autokowariancji lub autokorelacji;
- rozwiązanie zagadnienia regresyjnego metodą najmniejszych kwadratów błędów;
- rozwiązanie zagadnienia regresyjnego metodą rozszerzoną zwykłej metody najmniejszych kwadratów błędów.

W rozprawie zastosowano pierwszy sposób dla funkcji autokorelacji.

Funkcja autokorelacji (ang. ACF – *AutoCorrelation Function*) wykorzystywana jest do pomiaru zmienności sezonowej szeregów czasowych. Sezonowość jest zależnością korelacyjną rzędu k między i -tym elementem szeregu czasowego i i_k -tym elementem, gdzie k jest opóźnieniem [169], [358]. Sezonowość, dla szeregów czasowych nieobarczonych dużym błędem pomiaru, można identyfikować w sposób wizualny, na podstawie korelogramu, jako wzorzec powtarzający się co k elementów [312].

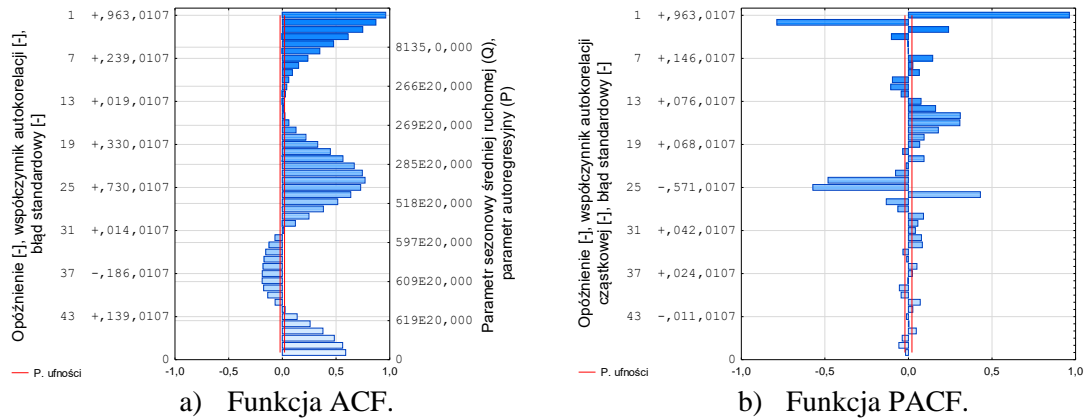
Korelogram służy do analizy struktury harmonicznej szeregu czasowego i zawiera graficzną i liczbową reprezentację funkcji autokorelacji przedstawianą za pomocą współczynników autokorelacji i ich błędów standardowych dla kolejnych opóźnień, dla których autokorelacje są formalnie zależne [312]. Korelogramy zawierają przedział wyznaczony przez dwa błędy standardowe, a w ich analizie priorytetowym parametrem pozwalającym na skuteczną analizę jest siła korelacji, natomiast drugorzędnym parametrem jest efektywność estymacji. Taka kolejność analizy korelogramu pozwala na wyodrębnienie korelacji o dużym poziomie istotności.

Rozwinięciem funkcji autokorelacji, służącej do badania struktury autokorelacji szeregów czasowych, jest funkcja autokorelacji cząstkowej (ang. PACF – *Partial Autocorrelation Function*), która pozbawiona jest zależności od elementów pośrednich wewnątrz opóźnienia [312]. Tym samym funkcja autokorelacji cząstkowej stanowi bardziej przejrzysty wgląd w występujące zależności dla poszczególnych opóźnień. Obliczanie autokorelacji cząstkowej polega na usunięciu korelacji ze wszystkimi elementami w ramach opóźnienia [23], [228]. Funkcja autokorelacji cząstkowej pozwala na identyfikację rzędu modeli autoregresyjnych ze względu na posiadaną właściwość, dzięki której przyjmuje ona wartości nieistotnie różne od zera dla opóźnień większych od rzędu pierwszego [286].

W rozprawie ze względu na wzajemną zależność kolejnych opóźnień nie stosuje się usuwania zależności szeregowych poprzez zastosowanie różnicowania szeregów czasowych ponieważ zmodyfikowana funkcja autokorelacji mogłaby utracić istotne autokorelacje lub wypuklić inne składniki okresowe.

Przykłady korelogramów funkcji ACF i PACF dla 48 godzinnych opóźnień w 2018 roku zamieszczone są na Rysunku 3.1.1.

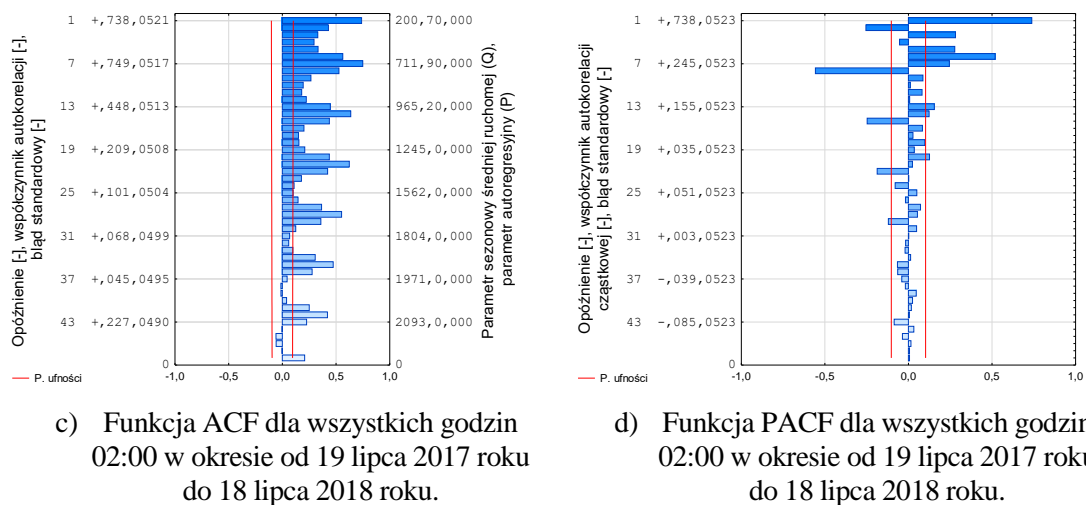
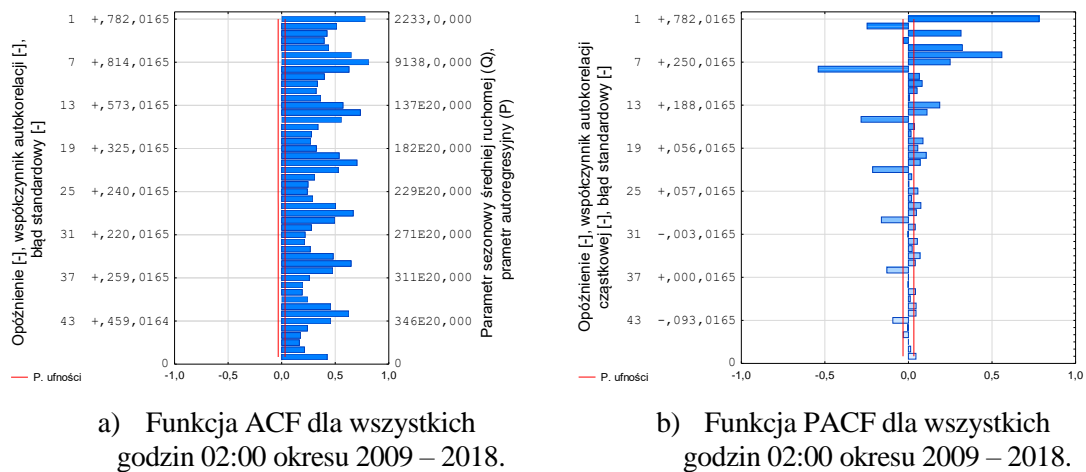
Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną metodą ważonych współczynników funkcji autokorelacji cząstkowej



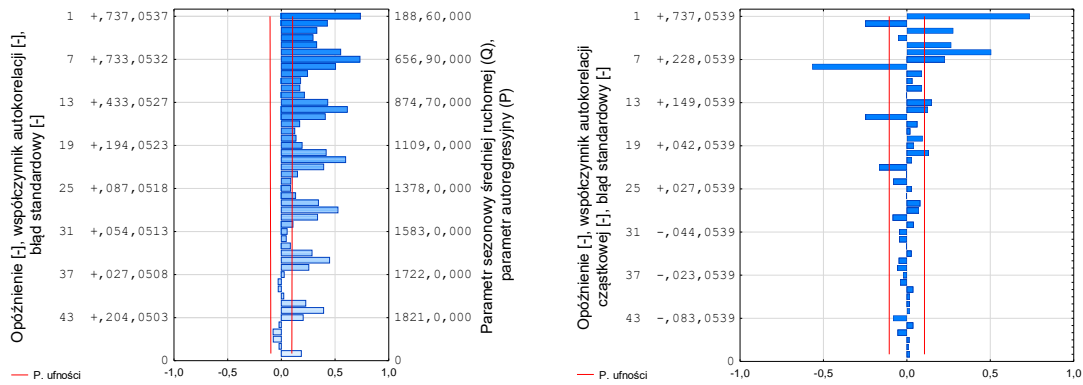
Rys. 3.1.1. Przykład korelogramu funkcji autokorelacji ACF i PACF zapotrzebowania na moc elektryczną w KSE w 2018 roku dla opóźnienia 48 dób.

Źródło: Opracowanie własne na podstawie programu STATISTICA® [344], [305], [312], [191].

Analogiczne korelogramy dla obu funkcji (Rys. 3.1.2) wskazują, że przedział ufności dla wszystkich godzin doby i całego dziesięcioletniego okresu analizy jest węższy niż dla wybranej godziny doby przy takiej samej liczbie określającej opóźnienie i jednego pełnego roku oraz 344 dób.



*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*



e) Funkcja ACF dla wszystkich godzin 02:00 w okresie od 09 sierpnia 2017 roku do 18 lipca 2018 roku.

f) Funkcja PACF dla wszystkich godzin 02:00 w okresie od 09 sierpnia 2017 roku do 18 lipca 2018 roku.

Rys. 3.1.2. Przykłady korelogramów funkcji autokorelacji ACF i PACF zapotrzebowania na moc elektryczną w KSE:

- a) i b) w okresie 2009 – 2018 dla wszystkich godzin 02:00,
- c) i d) w okresie 365 dni dla wszystkich godzin 02:00,
- e) i f) w okresie 344 dni dla wszystkich godzin 02:00.

Źródło: Opracowanie własne na podstawie programu STATISTICA® [344], [305], [312], [191].

3.2. Podstawy teoretyczne funkcji korelacji

3.2.1. Korelacja dwóch zmiennych i funkcja autokorelacji ACF

Korelacja dwóch zmiennych [21], [25], [169] może być przedstawiona za pomocą poniższej zależności zapisanej w dwojaki sposób (3.1.):

$$r_{xy} = \frac{cov(X, Y)}{\partial x \partial y} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (3.1.)$$

gdzie:

- \bar{x} – średnia wartość x ;
- \bar{y} – średnia wartości y .

Funkcja autokorelacji ACF [21], [25], [169] w doniesieniach teoretycznych i badaniach statystycznych wykorzystywana jest do wykrywania zależności pomiędzy dwoma szeregami czasowymi. Współczynnik funkcji korelacji przyjmuje wartości z przedziału $\langle -1; 1 \rangle$. Uzyskanie wartości 0 wskazuje na brak zależności pomiędzy badanymi szeregami czasowymi. Współczynnik funkcji autokorelacji stanowi wynik przeprowadzenie procesu obliczeniowego zbliżonego do obliczania współczynnika funkcji korelacji.

W przeciwieństwie do korelacji, w przypadku autokorelacji (3.2.) szereg czasowy jest korelowany sam ze sobą, a wartości z stanowią opóźnione wartości x .

$$r_{xx_p} = \frac{cov(X_i, X_{i-m})}{\partial(x)\partial(y)} = \frac{\sum_{i=1}^N (x_i - \bar{x}) * (z_{i-m} - \bar{z})}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (3.2.)$$

gdzie:

- \bar{x} – średnia wartość x ;
- \bar{z} – średnia wartości z ;
- m – wartość opóźnienia (przesunięcia).

Sekwencyjne powtórzenie obliczeń współczynników funkcji autokorelacji umożliwia wyprowadzenie wyników pod postacią korelogramu. Poziomy ufności (dwa poziomy) określone są w celu umożliwienia oceny losowości analizowanego szeregu. Pierwszy z poziomów to przedział ufności na poziomie 95%, który utrzymywany jest na stałym poziomie (3.3.) [[21], [25], [169]:

$$SE(r)_{95\%} = \frac{\pm 1,96}{\sqrt{N}} \quad (3.3.)$$

Cechą charakterystyczną drugiego poziomu ufności jest wzrost lub spadek wartości z czasem w przypadku korelacji ujemnych, co wynika z utraty aktualności posiadanych danych w miarę przesuwania się okna analizy w kierunku wartości historycznie najświeższych. Ten poziom ufności nazywany jest dużym przedziałem ufności (3.4.) [21], [25], [169]:

$$SE(r)_{D95\%} = \pm \sqrt{\frac{1 + 2 * \sum_{i=1}^{f-1} r_i^2}{N}} \text{ dla } f > 1 \quad (3.4.)$$

W odniesieniu do wzoru na 95% przedział ufności, jeżeli wyniki obliczeń reprezentowane przez poszczególne słupki korelogramu w znaczącej większości znajdują się poniżej poziomu ufności, można wywnioskować, że analizowany szereg czasowy posiada właściwości wyłącznie losowe.

W odniesieniu do dużego 95% przedziału ufności można powiedzieć, że stosowany jest w sytuacji, gdy dane w analizowanym szereg czasowym w miarę upływu czasu tracą na swojej aktualności. W związku z tym w analizowanym szereg czasowym dochodzi do wzrostów lub spadków jego wartości dla korelacji ujemnych.

Zauważalne jest, że wartości współczynników funkcji autokorelacji są pomocne przy opracowywaniu i procesie decyzyjnym dotyczącym budowania modeli prognostycznych w oparciu o metody ARMA oraz ARIMA.

3.2.2. Funkcja autokorelacji cząstkowej PACF

Autokorelacja cząstkowa mierzy zależność liniową jednej zmiennej po usunięciu innej zmiennej, która ma wpływ na obie zmienne. Na przykład autokorelacja cząstkowa dla z_{i-2} po usunięciu wpływu z_{i-1} zarówno dla z_i jak i z_{i-2} .

Każdą autokorelację cząstkową można przedstawić w postaci szeregu regresji (3.5.) [21], [25], [169]:

$$\tilde{y}_t = \phi_{21}\tilde{y}_{t-1} + \phi_{22}\tilde{y}_{t-2} + \xi_t \quad (3.5.)$$

gdzie:

- \tilde{y}_t – oryginalny szereg pomniejszony o średnią $y_t - \bar{y}$;
- ϕ_{22} – wartość autokorelacji cząstkowej dla rzędu 2 – go.

W celu obliczenia współczynników funkcji autokorelacji cząstkowej niezbędne jest obliczanie współczynników autoregresji. Przy założeniu szeregu czasowego zero – średniego typu dyskretnego $\{x_i\}_1^N$ o charakterze AR (autoregresyjnym) konieczne jest określenie rzędu $p = 1$ dla AR(p) oraz stosownych współczynników $\{\phi_i\}$.

Istnieją 2 metody obliczania współczynników autoregresji (3.6.) [[21], [25], [169]:

- 1) metoda inwersji bezpośredniej (dla ograniczonej liczby opóźnień czasowych p);
- 2) metoda równań Yule – Walker’a (dla dowolnej liczby opóźnień czasowych p).

$$x_{i+1} = \phi_1 x_i + \phi_2 x_{i-1} + \dots + \phi_p x_{i-p+1} + \xi_{i+1} \quad (3.6.)$$

gdzie:

x_i – pierwotne wartości szeregu czasowego pomniejszone o różnicę $x_i - \bar{x}$.

3.2.2.1. Metoda inwersji bezpośredniej

Przy założeniu, że (3.7. – 3.9.) [101], [102]:

- a) $p = 1$:

$$x_i = \phi_1 x_i + \xi_{i+1} \quad (3.7.)$$

$$\underbrace{\begin{pmatrix} x_2 \\ x_3 \\ \vdots \\ x_N \end{pmatrix}}_{\mathbf{b}} = \underbrace{\begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_{N-1} \end{pmatrix}}_{\mathbf{A}} \phi_1 \quad (3.8.)$$

$$\hat{\phi}_1 = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b} = \frac{\sum_{i=1}^{N-1} x_i x_{i+1}}{\sum_{i=1}^{N-1} x_i^2} = \frac{c_1}{c_0} = r_1 \quad (3.9.)$$

gdzie:

c_i – współczynnik autokowariancji;
 r_i – współczynnik autokorelacji.

Analogicznie przy założeniu, że [101], [102]:

- a) $p = 2$ (3.10. – 3.11.):

$$x_i = \phi_1 x_i + \phi_2 x_{i-1} + \xi_{i+1} \quad (3.10.)$$

$$\underbrace{\begin{pmatrix} x_3 \\ x_4 \\ \vdots \\ x_N \end{pmatrix}}_{\mathbf{b}} = \underbrace{\begin{pmatrix} x_2 & x_1 \\ x_3 & x_2 \\ \vdots & \vdots \\ x_{N-1} & x_{N-2} \end{pmatrix}}_{\mathbf{A}} \underbrace{\begin{pmatrix} \phi_1 \\ \phi_2 \end{pmatrix}}_{\mathbf{\Phi}} \quad (3.11.)$$

W przeciwieństwie do poprzednio rozpatrywanego $p = 1$, rozwiązanie równania jest bardziej skomplikowane (3.12.) [101], [102]:

$$\hat{\mathbf{\Phi}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b} \quad (3.12.)$$

Rozpoczynając od (3.13.) [101], [102]:

$$\begin{aligned}
 (\mathbf{A}^T \mathbf{A})^{-1} &= \left[\begin{pmatrix} x_2 & x_3 & \dots & x_{N-1} \\ x_1 & x_2 & \dots & x_{N-2} \end{pmatrix} \begin{pmatrix} x_2 & x_1 \\ x_3 & x_2 \\ \vdots & \vdots \\ x_{N-1} & x_{N-2} \end{pmatrix} \right]^{-1} = \\
 & \begin{pmatrix} \sum_{i=2}^{N-1} x_i^2 & \sum_{i=2}^{N-1} x_i x_{i-1} \\ \sum_{i=2}^{N-1} x_i x_{i-1} & \sum_{i=1}^{N-2} x_i^2 \end{pmatrix}^{-1} = \\
 & \frac{1}{\sum_{i=2}^{N-1} x_i^2 \sum_{i=1}^{N-2} x_i^2 - \sum_{i=2}^{N-1} x_i x_{i-1} \sum_{i=2}^{N-1} x_i x_{i-1}} \begin{pmatrix} \sum_{i=1}^{N-2} x_i^2 & -\sum_{i=2}^{N-1} x_i x_{i-1} \\ -\sum_{i=2}^{N-1} x_i x_{i-1} & \sum_{i=2}^{N-1} x_i^2 \end{pmatrix}
 \end{aligned} \tag{3.13.}$$

Zakładając następnie, że szereg czasowy jest stacjonarny w celu zapewnienia elementom autokowariancji by były funkcją wyłącznie opóźnienia czasowego, a nie dokładnych granic czasowych, w takim przypadku otrzymuje się poniższe równania (3.14. – 3.16.) [101], [102]:

$$(\mathbf{A}^T \mathbf{A})^{-1} = \frac{1}{c_0^2 - c_1^2} \begin{pmatrix} c_0 & -c_1 \\ -c_1 & c_0 \end{pmatrix} \tag{3.14.}$$

$$(\mathbf{A}^T \mathbf{A})^{-1} = \frac{1}{c_0^2(1 - r_1^2)} \begin{pmatrix} c_0 & -c_1 \\ -c_1 & c_0 \end{pmatrix} \tag{3.15.}$$

$$(\mathbf{A}^T \mathbf{A})^{-1} = \frac{1}{c_0(1 - r_1^2)} \begin{pmatrix} r_0 & -r_1 \\ -r_1 & r_0 \end{pmatrix} \tag{3.16.}$$

Analogicznie dla poniższego mnożenia macierzy transponowanej i wektora (3.17.) [101], [102]:

$$\mathbf{A}^T \mathbf{b} = \begin{pmatrix} x_2 & x_3 & \dots & x_{N-1} \\ x_1 & x_2 & \dots & x_{N-2} \end{pmatrix} \begin{pmatrix} x_2 \\ x_4 \\ \vdots \\ x_N \end{pmatrix} = \begin{pmatrix} \sum_{i=3}^N x_i x_{i-1} \\ \sum_{i=3}^N x_i x_{i-2} \end{pmatrix} \tag{3.17.}$$

gdzie po ponownym założeniu stacjonarności szeregu czasowego otrzymuje się następującą postać rozważanego powyżej iloczynu (3.18.) [101], [102]:

$$\mathbf{A}^T \mathbf{b} = \begin{pmatrix} c_1 \\ c_2 \end{pmatrix} \tag{3.18.}$$

Po połączeniu obu równań otrzymuje się (3.19.) [101], [102]:

$$(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b} = \frac{1}{c_0(1 - r_1^2)} \begin{pmatrix} r_0 & -r_1 \\ -r_1 & r_0 \end{pmatrix} \begin{pmatrix} c_1 \\ c_2 \end{pmatrix} = \frac{1}{1 - r_1^2} \begin{pmatrix} 1 & -r_1 \\ -r_1 & 1 \end{pmatrix} \begin{pmatrix} r_1 \\ r_2 \end{pmatrix} \tag{3.19.}$$

Po rozbiciu na dwa osobne elementy otrzymuje się następującą postać współczynników (3.20.) [101], [102]:

$$\hat{\phi}_1 = \frac{r_1(1 - r_2)}{1 - r_1^2} \tag{3.20.}$$

oraz (3.21.) [101], [102]:

$$\hat{\phi}_2 = \frac{r_2 - r_1^2}{1 - r_1^2} \tag{3.21.}$$

Dalsze rozważania dla $p \geq 3$ utrudniają analizę, ponieważ już dla $p = 3$ otrzymuje się macierz poniższej postaci (3.22.) [101], [102]:

$$\mathbf{A}^T \mathbf{A} = \begin{pmatrix} c_0 c_1 c_2 \\ c_1 c_0 c_1 \\ c_2 c_1 c_0 \end{pmatrix} \quad (3.22.)$$

Dla powyższego działania determinanta, wymagana do wykonania działania inwersji, przyjmuje następującą postać (3.23.) [101], [102]:

$$\det(\mathbf{A}^T \mathbf{A}) = c_0 \left(c_0^2 - 2c_1^2 + 2 \frac{c_1^2 c_2}{c_0} - c_2^2 \right) = c_0 [c_0^2 + 2c_1^2(r_2 - 1) - c_2^2] \quad (3.23.)$$

co po wstępnym przemnożeniu przez macierz reszt (ang. *Reminder Matrix*) daje bardzo złożone równania.

3.2.2.2. Metoda Równań Yule – Walker'a

Rozważając ogólną postać równania autoregresyjnego AR(p) (3.24.) [101], [102]:

$$x_{i+1} = \phi_1 x_i + \phi_2 x_{i-1} + \dots + \phi_p x_{i-p+1} + \xi_{i+1} \quad (3.24.)$$

Zakładając kolejne wartości opóźnień możliwe jest przeprowadzenie następującego rozumowania [101], [102]:

a) Opóźnienie 1:

Wykonane zostaną następujące działania:

i) Przemnożenie obu stron równania modelu przez x_i (3.25.) [101], [102]:

$$x_i x_{i+1} = \sum_{j=1}^p (\phi_j x_i x_{i-j+1}) + x_i \xi_{i+1} \quad (3.25.)$$

gdzie i oraz j są odpowiednio wskaźnikami czasu i wyrażenia,

ii) Dla wartości oczekiwanej (3.26.) [101], [102]:

$$\langle x_i x_{i+1} \rangle = \sum_{j=1}^p (\phi_j \langle x_i x_{i-j+1} \rangle) + \langle x_i \xi_{i+1} \rangle \quad (3.26.)$$

gdzie $\{\phi_j\}$ są utrzymywane poza operatorem wartości oczekiwanej ponieważ są raczej wielkościami natury deterministycznej, a nie statystycznej.

- Z uwagi na fakt, że wartość oczekiwana $\langle x_i \xi_{i+1} \rangle = 0$ dla składnika losowego bieżącego miejsca na osi czasu nie jest powiązana, i tym samym nie jest skorelowana, z poprzednią wartością analizowanego procesu to (3.27.) [101], [102]:

$$\langle x_i x_{i+1} \rangle = \sum_{j=1}^p (\phi_j \langle x_i x_{i-j+1} \rangle) \quad (3.27.)$$

- Po podzieleniu przez $(N - 1)$ oraz przy uwzględnieniu równości autokowariancji $c_{-l}=c_l$ oraz po (3.28.) [101], [102]:

$$c_1 = \sum_{j=1}^p \phi_j c_{j-1} \quad (3.28.)$$

- Po podzieleniu przez c_0 (3.29.) [101], [102]:

$$r_1 = \sum_{j=1}^p \phi_j r_{j-1} \quad (3.29.)$$

b) Opóźnienie 2:

Wykonane zostaną następujące działania:

- Przemnożenie obu stron równania modelu przez x_{i-1} skutkuje następującym równaniem (3.30.) [101], [102]:

$$x_{i-1}x_{i+1} = \sum_{j=1}^p (\phi_j x_{i-1}x_{i-j+1}) + x_{i-1}\xi_{i+1} \quad (3.30.)$$

- Dla wartości oczekiwanej uzyskuje się (3.31.) [101], [102]:

$$\langle x_{i-1}x_{i+1} \rangle = \sum_{j=1}^p (\phi_j \langle x_{i-1}x_{i-j+1} \rangle) + \langle x_{i-1}\xi_{i+1} \rangle \quad (3.31.)$$

- Eliminacja zerowej korelacji skutkuje poniższą zależnością (3.32.) [101], [102]:

$$\langle x_{i-1}x_{i+1} \rangle = \sum_{j=1}^p (\phi_j \langle x_{i-1}x_{i-j+1} \rangle) \quad (3.32.)$$

- Po podzieleniu przez $(N - 1)$ oraz przy uwzględnieniu równości autokowariancji $c_{-l}=c_l$ uzyskuje się (3.33.) [101], [102]:

$$c_2 = \sum_{j=1}^p \phi_j c_{j-2} \quad (3.33.)$$

- Po podzieleniu przez c_0 (3.34.) [101], [102]:

$$r_2 = \sum_{j=1}^p \phi_j r_{j-2} \quad (3.34.)$$

c) Opóźnienie k :

Wykonane zostaną następujące działania:

- Przemnożenie obu stron równania modelu przez x_{i-k+1} (3.35.) [101], [102]:

$$x_{i-k+1}x_{i+1} = \sum_{j=1}^p (\phi_j x_{i-k+1}x_{i-j+1}) + x_{i-k+1}\xi_{i+1} \quad (3.35.)$$

ii) Dla wartości oczekiwanej (3.36.) [101], [102]:

$$\langle x_{i-k+1}x_{i+1} \rangle = \sum_{j=1}^p (\phi_j \langle x_{i-k+1}x_{i-j+1} \rangle) + \langle x_{i-k+1}\xi_{i+1} \rangle \quad (3.36.)$$

iii) Eliminacja zerowej korelacji skutkuje (3.37.) [101], [102]:

$$\langle x_{i-k+1}x_{i+1} \rangle = \sum_{j=1}^p (\phi_j \langle x_{i-k+1}x_{i-j+1} \rangle) \quad (3.37.)$$

iv) Po podzieleniu przez $(N-1)$ oraz przy uwzględnieniu równości autokowariancji $c_{-l}=c_l$ (3.38.) [101], [102]:

$$c_k = \sum_{j=1}^p \phi_j c_{j-k} \quad (3.38.)$$

v) Po podzieleniu przez c_0 (3.39.) [101], [102]:

$$r_k = \sum_{j=1}^p \phi_j r_{j-k} \quad (3.39.)$$

d) Opóźnienie p

Wykonane zostaną następujące działania:

i) Przemnożenie obu stron równania modelu przez x_{i-p-1} (3.40.) [101], [102]:

$$x_{i-p+1}x_{i+1} = \sum_{j=1}^p (\phi_j x_{i-p}x_{i-j+1}) + x_{i-p+1}\xi_{i+1} \quad (3.40.)$$

ii) Dla wartości oczekiwanej (3.41.) [101], [102]:

$$\langle x_{i-p+1}x_{i+1} \rangle = \sum_{j=1}^p (\phi_j \langle x_{i-p+1}x_{i-j+1} \rangle) + \langle x_{i-p+1}\xi_{i+1} \rangle \quad (3.41.)$$

iii) Eliminacja zerowej korelacji skutkuje (3.42.) [101], [102]:

$$\langle x_{i-p+1}x_{i+1} \rangle = \sum_{j=1}^p (\phi_j \langle x_{i-p+1}x_{i-j+1} \rangle) \quad (3.42.)$$

iv) Po podzieleniu przez $(N-1)$ oraz przy uwzględnieniu równości autokowariancji $c_{-l}=c_l$ (3.43.) [101], [102]:

$$c_p = \sum_{j=1}^p \phi_j c_{j-p} \quad (3.43.)$$

v) Po podzieleniu przez c_0 (3.44.) [101], [102]:

$$r_p = \sum_{j=1}^p \phi_j r_{j-p} \quad (3.44.)$$

e) Złożenie wcześniejszych rozważań:

Przepisanie na nowo wcześniejszych równań skutkuje (3.45. – 3.46.) [101], [102]:

$$\begin{aligned} r_1 &= \phi_1 r_0 + \phi_2 r_1 + \phi_3 r_2 + \dots + \phi_{p-1} r_{p-2} + \phi_p r_{p-1} \\ r_2 &= \phi_1 r_1 + \phi_2 r_0 + \phi_3 r_1 + \dots + \phi_{p-1} r_{p-3} + \phi_p r_{p-2} \end{aligned} \quad (3.45.)$$

$$\begin{aligned} r_{p-1} &= \phi_1 r_{p-2} + \phi_2 r_{p-3} + \phi_3 r_{p-4} + \dots + \phi_{p-1} r_0 + \phi_p r_1 \\ r_p &= \phi_1 r_{p-1} + \phi_2 r_{p-2} + \phi_3 r_{p-3} + \dots + \phi_{p-1} r_1 + \phi_p r_0 \end{aligned} \quad (3.46.)$$

co może zostać zapisane jak poniżej (3.47.) [101], [102]:

$$\begin{pmatrix} r_1 \\ r_2 \\ \vdots \\ r_{p-1} \\ r_p \end{pmatrix} = \begin{pmatrix} r_0 & r_1 & r_2 & \dots & r_{p-2} & r_{p-1} \\ r_1 & r_0 & r_1 & \dots & r_{p-3} & r_{p-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ r_{p-2} & r_{p-3} & r_{p-4} & \dots & r_0 & r_1 \\ r_{p-1} & r_{p-2} & r_{p-3} & \dots & r_1 & r_0 \end{pmatrix} \begin{pmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_{p-1} \\ \phi_p \end{pmatrix} \quad (3.47.)$$

Mając na uwadze, że $r_0 = 1$, powyższe równanie może zostać zapisane pod postacią (3.48.) [101], [102]:

$$\underbrace{\begin{pmatrix} r_1 \\ r_2 \\ \vdots \\ r_{p-1} \\ r_p \end{pmatrix}}_{\mathbf{r}} = \underbrace{\begin{pmatrix} 1 & r_1 & r_2 & \dots & r_{p-2} & r_{p-1} \\ r_1 & 1 & r_1 & \dots & r_{p-3} & r_{p-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ r_{p-2} & r_{p-3} & r_{p-4} & \dots & 1 & r_1 \\ r_{p-1} & r_{p-2} & r_{p-3} & \dots & r_1 & 1 \end{pmatrix}}_{\mathbf{R}} \underbrace{\begin{pmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_{p-1} \\ \phi_p \end{pmatrix}}_{\mathbf{\Phi}} \quad (3.48.)$$

lub pod postacią zwartą (3.49.) [101], [102]:

$$\mathbf{R}\mathbf{\Phi} = \mathbf{r} \quad (3.49.)$$

Należy zauważyć, że jest to układ dobrze dopasowany (o kwadratowej macierzy współczynników \mathbf{R}). Powyższe oznacza, że jest to układ o tej samej liczbie ograniczeń (czyli równań w rzędach \mathbf{R}) jako niewiadomych (elementach ϕ_j nieznanego wektora $\mathbf{\Phi}$). Ponadto macierz \mathbf{R} jest pełna i symetryczna w celu zapewnienia jej odwracalności (3.50.) [101], [102]:

$$\hat{\mathbf{\Phi}} = \mathbf{R}^{-1}\mathbf{r} \quad (3.50.)$$

W celu obliczenia autokorelacji cząstkowej konieczne jest w pierwszym kroku obliczenie autokorelacji do odpowiedniej wartości granicznej. Przykładowo dla $p \simeq N/4$. W kolejnym kroku przy założeniu, że wektor $\mathbf{r}^{(i)}$ prawej strony równania (3.49) dla przypadku $p = i$ oraz przy założeniu, że $\mathbf{R}^{(i)}$ jest współczynnikiem macierzy dla tego samego przypadku otrzymuje się [101], [102]:

f) Pętlę dla i , $1 \leq i \leq p$

i) obliczana jest macierz $\mathbf{R}^{(i)}$ oraz wektor $\mathbf{r}^{(i)}$

ii) odwracany jest wektor $\hat{\mathbf{\Phi}}^{(i)}$ (3.51.) [101], [102]:

$$\hat{\mathbf{\Phi}}^{(i)} = (\mathbf{R}^{(i)})^{-1}\mathbf{r}^{(i)} = \begin{pmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \\ \vdots \\ \hat{\phi}_i \end{pmatrix} \quad (3.51.)$$

iii) odrzucane są wszystkie współczynniki $\hat{\phi}_j$ dla $1 \leq j \leq i - 1$

- iv) pozostawiane są współczynniki $\hat{\phi}_i$, co daje współczynnik funkcji autokorelacji cząstkowej (3.52.) [101], [102]:

$$PACF(i) = \hat{\phi}_i \quad (3.52.)$$

- v) pętla obliczeniowa zakańczana jest po osiągnięciu i po czym możliwe jest wprowadzenie wyników obliczeń w funkcji i .

3.3. Koncepcja i założenia metody ważonych współczynników funkcji autokorelacji cząstkowej

Założeniem pracy jest opracowanie szybkiej i intuicyjnej metody tworzenia krótkoterminowych prognoz zapotrzebowania na moc elektryczną w KSE, co wpisuje się w potrzeby polskiego OSP związane z uniezależnieniem się od danych zewnętrznych zasilających modele prognostyczne przy jednoczesnym zachowaniu poziomu jakości prognoz. Opracowana metoda ma na celu wspomagać prognozy tworzone w ramach drugiej wersji planów koordynacyjnych dobowych przez PSE S.A. na jedną dobę do przodu (doba $n+1$).

Przyjęto następujące założenia:

- a) autoregresyjne właściwości historycznych krzywych obciążenia (sezonowość, okresowość) pozwolą na pominięcie trudnych, czasochłonnych i drogich metod budowania modeli prognostycznych (np. metody typu ARIMA [4], [224], [342]), a wykorzystanie współczynników funkcji autokorelacji będzie wystarczające do zbudowania modeli prognostycznych pozwalających na tworzenie krótkoterminowych prognoz zapotrzebowania na moc elektryczną na poziomie zbliżonym lub lepszym do skuteczności drugiej wersji planów PKD opracowywanych z dobowym wyprzedzeniem (na dobę $n+1$) przez PSE S.A. (publikacja do godz. 17:00 doby poprzedzającej wyznaczony horyzont prognostyczny dla kolejnej doby);
- b) współczynniki funkcji autokorelacji cząstkowej obliczono z wykorzystaniem pakietu STATISTICA®;
- c) współczynniki funkcji autokorelacji obliczane w pakiecie STATISTICA® zgodnie z doniesieniami literaturowymi;
- d) przed przystąpieniem do właściwych badań potwierdzono doniesienia literaturowe dotyczące skuteczniejszego prognozowania z wykorzystaniem współczynników funkcji autokorelacji cząstkowej względem prognozowania z wykorzystaniem współczynników funkcji korelacji, co wynika z ograniczenia nadmiaru informacji zawartych w wartościach współczynników funkcji autokorelacji cząstkowej [101] oraz uzyskano zgodę prof. Gidona Eshela dotyczącą możliwości wykorzystania formuł matematycznych zaprezentowanych w [101] i [102] dla potrzeb badań wstępnych poprzedzających wykorzystanie środowiska STATISTICA®;
- e) współczynniki funkcji autokorelacji cząstkowej wyliczono dla minionych 15 obserwacji (15 wcześniejszych analizowanych poszczególnych godzin doby) dla szeregów czasowych obejmujących dane za kolejne lata z zakresu od 2009 roku do 2018 roku;

- f) Testy efektywności opracowywanych prognoz opracowano dla wybranego przedziału godzin nocnych dla każdej doby 2018 roku.

W ramach badań:

- a) wyliczone współczynniki funkcji autokorelacji wykorzystywano do testowania na wszystkich analizowanych latach z osobna;
- b) opracowano indywidualny model matematyczny [158], polegający na mnożeniu wyznaczonych współczynników funkcji autokorelacji dla 15 wcześniejszych obserwacji przez odpowiadające im wartości obserwacji obciążeń KSE, które to iloczyny następnie zostały podzielone przez sumaryczne wartości współczynników funkcji autokorelacji dla wspomnianych obserwacji.

3.4. Formuły matematyczne modelu wykorzystującego metodę ważonych współczynników funkcji autokorelacji cząstkowej

3.4.1. Podejście klasyczne

Opracowany model (4.53.) wykorzystuje współczynniki funkcji autokorelacji cząstkowej dla x opóźnień występujących przed dobą n na podstawie danych historycznych obejmujących minione y dób kalendarzowych występujących przed dobą n . Wyliczone współczynniki są następnie wykorzystywane w celu prognozowania zapotrzebowania z osobna dla kolejnych 365 dób.

$$\frac{(r_{n-1} * P_{n-1} + r_{n-2} * P_{n-2} + \dots + r_{n-x} * P_{n-x}) \text{ dla } y \text{ dób roku kalendarzowego}}{\Sigma(r_{n-1} + r_{n-2} + \dots + r_{n-x}) \text{ dla } 365 \text{ dób roku kalendarzowego}} \quad (4.53.)$$

gdzie:

- x — cyfra lub liczba odzwierciedlająca numer opóźnienia występującego przed dobą n ;
- y — cyfra lub liczba odzwierciedlająca liczbę dób kalendarzowych poprzedzających dobę n .

3.4.2. Podejście krokowe

Model wynikający z zastosowania podejścia krokowego (4.54.) wykorzystuje współczynniki funkcji autokorelacji cząstkowej dla n opóźnień jak w przypadku modelu klasycznego jednakże każda kolejna doba obejmuje wsad historyczny bazujący na z dobach poprzedzających dobę n . Wyliczone współczynniki są następnie wykorzystywane w celu prognozowania każdej godziny z osobna kolejnych 365 dób.

$$\frac{(r_{n-1} * P_{n-1} + r_{n-2} * P_{n-2} + \dots + r_{n-x} * P_{n-x}) \text{ dla } z \text{ dób przed dobą } n}{\Sigma(r_{n-1} + r_{n-2} + \dots + r_{n-x}) \text{ dla } 365 \text{ dób przed dobą } n} \quad (4.54.)$$

gdzie:

- x — cyfra lub liczba odzwierciedlająca numer opóźnienia występującego przed dobą n ;
- z — cyfra lub liczba odzwierciedlająca liczbę dób poprzedzających dobę n .

3.4.3. Kalibracja modelu matematycznego

Kalibracja modelu matematycznego przeprowadzona została na danych historycznych KSE. Szczegóły postępowania przedstawiają się następująco:

- 1) dla parametru x :
 - a) dla podejścia klasycznego;
 - b) dla podejścia krokowego.
- 2) dla parametru y :
 - a) dla podejścia klasycznego;
- 3) dla parametru z :
 - b) dla podejścia krokowego.

W podejściu klasycznym wstępnym badaniom poddano 104 przypadki dób poprzedzających od 8 do 729, z krokiem 7 dób dla wszystkich godzin doby całego dziesięcioletniego szeregu czasowego. Opóźnienia przetestowano począwszy od 2 do 365. Prognozy o największej skuteczności dla doby następnej (6,59%) uzyskano dla 344 dób poprzedzających i opóźnienia o wartości 15. W podejściu krokowym wstępnym badaniom poddano 52 przypadki dób poprzedzających od 8 do 365 z krokiem 7 dób, dla każdej doby z osobna całego dziesięcioletniego szeregu czasowego. Opóźnienia przetestowano począwszy od 2 do 365. Prognozy o największej uśrednionej jakości dla wszystkich godzin doby (8,02%) i opóźnienia o wartości 15 uzyskano dla 281 dób poprzedzających wykonanie prognozy dla doby następnej.

Wadą podejścia krokowego jest znacząca czasochłonność w porównaniu do podejścia klasycznego oraz mniejsza jakość uzyskiwanych prognoz.

Ze względu na uzyskanie większej skuteczności wstępnych prognoz dla podejścia klasycznego zakwalifikowano je do szczegółowych badań walidacyjnych.

3.5. Założenia i dane wejściowe

Walidacja metody, polegająca na ocenie efektywności prognoz (błąd MAPE, %) otrzymywanych za pomocą opracowanej metody, przeprowadzona została w trzech obszarach:

- Z wykorzystaniem danych o wielkości zapotrzebowania na moc elektryczną w KSE w porównaniu do skuteczności prognozowania osiąganą przez polskiego operatora systemu przesyłowego.
- Z wykorzystaniem danych o wielkości zapotrzebowania na moc elektryczną w szwedzkim i francuskim systemie elektroenergetycznym w porównaniu do efektywności prognozowania osiąganą przez tych operatorów systemów przesyłowych.
- Z wykorzystaniem danych o wielkości zapotrzebowania na moc elektryczną w KSE w porównaniu do jakości prognozowania osiąganą przez 80 modeli wybranych metod autoregresyjnych zasilanych danymi o wielkości zapotrzebowania na moc elektryczną w KSE.

Danymi wejściowymi do modeli matematycznych budowanych w oparciu o opracowaną metodę klasyczną i krokową ważonych współczynników funkcji autokorelacji cząstkowej, wykorzystującą metodę równań Yule – Walker’a, były szeregi czasowe odzwierciedlające godzinowe wartości zapotrzebowania na moc elektryczną w KSE określające dobowe profile jego obciążenia. Analizie poddano historyczne wartości zapotrzebowania na moc elektryczną w KSE od 2009 roku do 2018 roku. Źródłem pochodzenia danych historycznych wykorzystanych w badaniach symulacyjnych jest witryna internetowa PSE S.A. [256]. Dane źródłowe (dane historyczne) posłużyły do opracowania prognoz zapotrzebowania na moc elektryczną w KSE, również w rozdzielczości godzinowej. Horyzontem prognostycznym jest doba $n+1$. Weryfikacja skuteczności wyrażanej w procentach błędu MAPE opracowywanych prognoz przeprowadzona została poprzez wsteczne (*ex post*) porównanie z jakością uzyskiwaną dla KSE. Skuteczność prognoz osiąganych przez PSE S.A. obliczana jest jako odniesienie (wyrażane wartościami procentowymi) Bieżących Planów Koordynacyjnych Dobowych publikowanych przez PSE S.A. [256] na dobę $n+1$ do danych historycznych o wielkości godzinowego zapotrzebowania na moc elektryczną w KSE. Opisane powyżej podejście stanowi pierwszy zbiór walidacyjny dla opracowanej metody ważonych współczynników funkcji autokorelacji cząstkowej.

W ramach drugiego zbioru walidacyjnego przetestowano efektywność metody ważonych współczynników funkcji autokorelacji cząstkowej na danych historycznych obciążeń zagranicznych systemów elektroenergetycznych, do których zaliczono systemy Szwecji i Francji. Dobór systemów podyktowany był zaawansowanym poziomem funkcjonowania rynków energii elektrycznej oraz zamożnością społeczeństw i zróżnicowaniem odbiorców. Dane historyczne dla tych systemów udostępniane przez poszczególnych OSP obejmują zakres czasowy jedynie od 2013 roku do 2018 roku co zmniejsza możliwość bezpośredniej i jednoznacznej oceny porównawczej. Niemniej okres 6 lat danych historycznych i historycznych prognoz dla systemów zagranicznych stanowi pokaźną bazę dla badania odporności opracowanej metody na inne szeregi czasowe obciążeń systemów elektroenergetycznych. Operatorzy zagranicznych systemów przesyłowych udostępniają również za wskazany okres opracowywane prognozy zarządzanych przez siebie systemów elektroenergetycznych. Porównanie prognoz z rzeczywistym zapotrzebowaniem na moc elektryczną pozwala na ocenę porównawczą efektywności prognoz w odniesieniu do metody ważonych współczynników funkcji autokorelacji cząstkowej.

W ramach trzeciego zbioru walidacyjnego przeprowadzone są badania porównawcze opracowanej metody z wybranymi metodami prognostycznymi autoregresyjnymi. Danymi zasilającymi modele wybranych metod są dane historyczne i historyczne prognozy, za okres 2009 – 2018, dla KSE. Badania symulacyjne prognoz opracowano dla 80 różnych modeli prognostycznych z grup metod wykładniczego, metod autoregresji innych rzędów, metod regresji wielorakiej, metody autoregresyjnej wykorzystującej opóźnione szeregi czasowe, metody ARIMA, metody naiwnej z opóźnieniem siedmiu dób i jednej doby, metody najmniejszych kwadratów błędów i metody średniej kroczącej dwuokresowej.

3.6. Procedura badawcza

Celem podstawowych badań symulacyjnych jest wykonanie wygasłych prognoz (*ex post*) zapotrzebowania na moc elektryczną z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej dla KSE, dla zagranicznych systemów elektroenergetycznych oraz dla KSE z wykorzystaniem wybranych metod i modeli prognostycznych dla każdej godziny doby przy użyciu metody ważonych współczynników funkcji autokorelacji cząstkowej w następujących krokach.

- 1) Wykonanie badań symulacyjnych dla parametrów umożliwiających kalibrację i analizę wrażliwości dla podejścia klasycznego i krokowego opracowanej metody ważonych współczynników funkcji autokorelacji cząstkowej.
- 2) Porównanie uzyskanych wyników oraz przeprowadzenie skuteczniejszego podejścia.
- 3) Opracowanie analizy dopuszczalności prognoz opracowanych z zastosowaniem metody ważonych współczynników funkcji autokorelacji cząstkowej.
- 4) Przeprowadzenie analiz w trybie wygasłym (*ex post*) dla każdej doby $n+1$ z analizowanego okresu, dla którego posiadane są dane historyczne o kształtowaniu zapotrzebowania na moc elektryczną w KSE. Dane historyczne (prognozy i ich realizacja) posiadają rozdzielczość godzinową. Otrzymane wyniki określające efektywność prognoz wyrażone są w wartościach procentowych.
- 5) Opracowanie prognoz zapotrzebowania na moc elektryczną z uwzględnieniem szeregów czasowych reprezentujących obciążenia systemu szwedzkiego i francuskiego oraz porównanie uzyskanej skuteczności ze skutecznością prognozowania uzyskanego dla KSE.
- 6) Opracowanie prognoz zapotrzebowania na moc elektryczną z wykorzystaniem wybranych metod i modeli prognostycznych oraz porównanie uzyskanej skuteczności ze skutecznością prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej.

3.7. Podejście klasyczne a podejście krokowe

Porównanie wyników prognoz (Tab. 3.7.1), dla podejścia klasycznego i krokowego, wskazuje (za cały dziesięcioletni okres analizy) na większą skuteczność (6,63%) dla podejścia klasycznego w stosunku do podejścia krokowego (8,02%). Podejście klasyczne daje mniej skuteczne prognozy w porównaniu do prognoz uwzględnianych w planach BPKD na poziomie 5,81% za cały okres analizy. Wynikiem takiego samego porównania dla podejścia krokowego jest regresja jakości prognoz o 7,20% w skali całego okresu analizy.

Tab. 3.7.1. Skuteczność roczna prognoz osiąganych przy pomocy metody ważonych współczynników funkcji autokorelacji cząstkowej a skuteczność prognoz w ramach BPKD (podejście klasyczne a podejście krokowe) wyrażona wartościami błędu MAPE, [%].

Rok	Podejście klasyczne			Podejście krokowe		
	Metoda ważonych współczynników funkcji autokorelacji cząstkowej	BPKD (PSE S.A.)	Różnica	Metoda ważonych współczynników funkcji autokorelacji cząstkowej	BPKD (PSE S.A.)	Różnica
–	1	2	1 a 2	3	2	3 a 2
2009	5,82	1,28	4,54	7,38	1,28	6,10
2010	6,31	0,85	5,46	7,42	0,85	6,57
2011	6,23	0,81	5,42	7,56	0,81	6,75
2012	6,57	0,78	5,79	7,99	0,78	7,21
2013	6,77	0,75	6,02	7,63	0,75	6,88
2014	6,80	0,74	6,06	8,26	0,74	7,52
2015	6,81	0,79	6,02	8,61	0,79	7,82
2016	6,93	0,75	6,18	8,37	0,75	7,62
2017	6,74	0,74	6,00	8,41	0,74	7,67
2018	7,31	0,71	6,60	8,52	0,71	7,81
średnia	6,63	0,82	5,81	8,02	0,82	7,20

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Największa efektywność osiągnięta jest przy zastosowaniu podejścia klasycznego. Najlepszy wynik uzyskuje się dla 15 opóźnień dla prognozowania dla doby $n+1$.

4. Walidacja opracowanego modelu do prognozowania zapotrzebowania na moc elektryczną wykorzystującego metodę ważonych współczynników funkcji autokorelacji cząstkowej

4.1. Dopuszczalność prognoz

4.1.1. Kryteria dopuszczalności prognoz w literaturze przedmiotu

Kryteria dopuszczalności prognoz w literaturze przedmiotu wskazują na przedziały zaprezentowane w kolumnie nr. 2 Tabeli 4.1.1.1 ([371], [36], [35], [130]). Kryteria te określone są dla zastosowanego miernika dokładności prognoz *ex post*, którym w rozprawie jest błąd MAPE. Kryteria wskazywane w literaturze przedmiotu, w porównaniu z jakością prognoz opracowywanych dla potrzeb prognozowania w dużych systemach elektroenergetycznych, są szerokie, dlatego też zaproponowano ich zawężenie. Zawężone wartości i przedziały dopuszczalności (jakości) prognoz zaprezentowane są w kolumnie nr 3 Tabeli 4.1.1.1. Procentowe wartości wynikające z zawężenia kryteriów przedstawia kolumna nr. 4. W ostatniej kolumnie Tabeli 4.1.1.1 zamieszczono skróty, które ułatwiają przegląd spełnienia kryteriów dopuszczalności prognoz.

Tab. 4.1.1.1. Kryteria dopuszczalności prognoz w literaturze przedmiotu i zastosowane w rozprawie.

Jakość prognoz	Kryteria literaturowe oceny skuteczności prognoz	Kryteria oceny skuteczności prognoz przyjęte w rozprawie	Różnica wartości kryteriów	Skrót
Bardzo dokładne	$Y_n^P \leq 3,00\%$	$Y_n^P \leq 2,00\%$	1,00%	BD
Dokładne	$3,00\% < Y_n^P \leq 5,00\%$	$2,00\% < Y_n^P \leq 4,00\%$	1,00% i 1,00%	D
Dopuszczalne	$5,00\% < Y_n^P \leq 10,00\%$	$4,00\% < Y_n^P \leq 6,00\%$	1,00% i 4,00%	DP
Niedopuszczalne	$Y_n^P > 10,00\%$	$Y_n^P > 6,00\%$	4,00%	ND

Legenda: Y_n^P : skuteczność prognozy.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.1.2. Założenia względem kryterium dopuszczalności prognoz

Wyniki zaprezentowane w tym rozdziale nawiązują do zawężonych kryteriów akceptacji prognoz zamieszczonych w Tabeli 4.1.1.1. Skuteczność prognoz niedopuszczalnych (ND) przekracza wartość 6,00%, dla prognoz dopuszczalnych zawiera się w przedziale prawostronnie domkniętym pomiędzy 4,00% i 6,00%. Prognozy dokładne (D) zawierają się w przedziale prawostronnie domkniętym pomiędzy 2,00% i 4,00%, natomiast prognozy bardzo dokładne (BD) kształtują się na poziomie równym lub mniejszym od 2,00% [371], [36], [35], [130]. Ułatwieniem odczytu dopuszczalności prognoz jest podświetlenie poszczególnych wyników w następujący sposób: kolor jasnozielony – prognozy DP, kolor zielony – prognozy D i kolor ciemnozielony – prognozy BD.

4.1.3. Analiza dopuszczalności ogólna

Tabela 4.1.3.1 przedstawia prognozy uzyskane dla metody ważonych współczynników funkcji autokorelacji cząstkowej bazującej na danych historycznych o kształtowaniu zapotrzebowania na moc elektryczną w KSE w latach 2009 – 2018. Prognozy uzyskane z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej w podziale na poszczególne lata dziesięcioletniego okresu analizy dla wszystkich godzin doby nie spełniają kryterium dopuszczalności. Dla godzin 00:00 – 05:00 dla wszystkich lat, z wyjątkiem 2009 roku, spełniają kryterium dopuszczalności. W odniesieniu do godzin 06:00 – 23:00, podobnie jak dla całej doby analizowanego okresu, uzyskane prognozy nie spełniają kryterium dopuszczalności.

Tab. 4.1.3.1. Dopuszczalność prognoz w podziale lata oraz na typy dni i godziny doby dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Rok	Cała doba	00:00 – 05:00	06:00 – 23:00	Dzień	Cała doba	00:00 – 05:00	06:00 – 23:00
2009	ND	ND	ND	Poniedziałek	ND	DP	ND
2010	ND	DP	ND	Wtorek	ND	ND	DP
2011	ND	DP	ND	Środa	D	D	D
2012	ND	DP	ND	Czwartek	D	D	D
2013	ND	DP	ND	Piątek	DP	D	DP
2014	ND	DP	ND	Sobota	ND	DP	ND
2015	ND	DP	ND	Niedziela	ND	ND	ND
2016	ND	DP	ND	Dni robocze	ND	DP	ND
2017	ND	DP	ND	Dni wolne od pracy	ND	ND	ND
2018	ND	DP	ND	Dni świąteczne	ND	ND	ND
<i>średnia</i>	<i>ND</i>	<i>DP</i>	<i>ND</i>	–	–	–	–

Legenda: BD: prognoza bardzo dokładna; D: prognoza dokładna (kolor zielony); DP: prognoza dopuszczalna (kolor jasnozielony); ND: prognoza niedopuszczalna (kolor ciemnozielony).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

W odniesieniu do dni tygodnia dla całej doby, prognozy uzyskane dla metody ważonych współczynników funkcji autokorelacji cząstkowej są spełniają kryterium dopuszczalności dla piątków, dobre dla śród i czwartków oraz nie spełniają go dla poniedziałków, wtorków, sobót, niedziel oraz dni świątecznych i niestandardowych. Opracowana metoda ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 pozwala na osiągnięcie prognoz spełniających kryterium dopuszczalności dla poniedziałków i sobót oraz prognoz dokładnych dla śród, czwartków i piątków. W tym zakresie godzinowym jako niedopuszczalne należy uznać prognozy dla wtorków, niedziel oraz dni świątecznych i niestandardowych. Dla zakresu godzin 06:00 – 23:00 prognozami spełniającymi kryterium dopuszczalności są prognozy dla wtorków i piątków, natomiast prognozami dokładnymi są prognozy dla śród i czwartków. Prognozy dla poniedziałków, sobót, niedziel oraz dni świątecznych i niestandardowych nie spełniają kryterium dopuszczalności. Szczegółowe zestawienie dopuszczalności prognoz w przedziale godzin 00:00 – 05:00 w poszczególnych latach okresu analizy (Tab. 4.1.3.2) wskazuje, że prognozy uzyskane metodą ważonych współczynników funkcji autokorelacji cząstkowej spełniają kryterium dopuszczalności dla pierwszych pięciu godzin doby, natomiast nie spełniają tego kryterium wyłączenie dla ostatniej godziny analizowanego zakresu pierwszych sześciu godzin doby.

Zestawienie dopuszczalności prognoz dla godzin doby od 06:00 do 23:00 w poszczególnych latach okresu analizy przedstawia Tabela 4.1.3.3. Dopuszczalność prognoz odnotowywana jest wyłącznie dla godziny 22:00 i 23:00.

Tab. 4.1.3.2. Dopuszczalność prognoz w poszczególnych latach 2009 – 2018 w godzinach 00:00 – 05:00 dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
00:00	DP	DP	DP	DP	DP	DP	DP	DP	DP	DP	DP
01:00	DP	DP	DP	DP	DP	DP	DP	DP	DP	DP	DP
02:00	ND	DP	DP	DP	DP	DP	DP	DP	DP	DP	DP
03:00	ND	DP	DP	DP	DP	DP	DP	DP	DP	DP	DP
04:00	ND	DP	DP	DP	DP	DP	DP	DP	DP	ND	DP
05:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
<i>średnia</i>	<i>ND</i>	<i>DP</i>	<i>DP</i>	<i>DP</i>	<i>DP</i>	<i>DP</i>	<i>DP</i>	<i>DP</i>	<i>DP</i>	<i>DP</i>	<i>DP</i>

Legenda: BD: prognoza bardzo dokładna; D: prognoza dokładna (kolor zielony); DP: prognoza dopuszczalna (kolor jasnozielony); ND: prognoza niedopuszczalna (kolor ciemnozielony).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.1.3.3. Dopuszczalność prognoz w poszczególnych latach 2009 – 2018 w godzinach 06:00 – 23:00 dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
06:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
07:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
08:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
09:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
10:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
11:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
12:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
13:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
14:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
15:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
16:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
17:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
18:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
19:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
20:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
21:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
22:00	DP	DP	DP	DP	DP	DP	DP	ND	DP	ND	DP
23:00	DP	DP	DP	DP	DP	DP	DP	DP	DP	DP	DP
<i>średnia</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>

Legenda: BD: prognoza bardzo dokładna; D: prognoza dokładna (kolor zielony); DP: prognoza dopuszczalna (kolor jasnozielony); ND: prognoza niedopuszczalna (kolor ciemnozielony).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.1.4. Analiza dopuszczalności dla typów dni

Ocena dopuszczalności prognoz dla poszczególnych typów dni w godzinach 00:00 – 05:00 zamieszczona jest w Tabeli 4.1.4.1. Prognozy uzyskane metodą ważonych współczynników funkcji autokorelacji cząstkowej są niedopuszczalne dla wtorków, niedziel, dni weekendowych stanowiących średnią arytmetyczną z sobót i niedziel, dla całej grupy dni świątecznych i niestandardowych oraz dla Wigilii Świąt Bożego Narodzenia. W godzinie 05:00 niedopuszczalność prognozy odnotowywana jest dla poniedziałków i sobót. Dopuszczalność prognozy zauważalna jest dla wszystkich dni roboczych, pomimo odnotowywania niedopuszczalności prognoz dla wtorków. Dopuszczalność prognozy dla dni roboczych wynika z dokładnych prognoz uzyskiwanych dla pięciu z sześciu godzin w poniedziałki i dokładnych prognoz otrzymywanych dla śród (wszystkie godziny z analizowanego przedziału), czwartków

(wszystkie godziny z analizowanego przedziału) i piątków (wszystkie godziny z analizowanego przedziału). Dopuszczalność prognozy dla poniedziałków zastępowana jest przez prognozy dokładne z wyjątkiem godziny 05:00, dla której odnotowywana jest niedopuszczalność prognoz. Soboty, dzięki uzyskaniu dobrych jakościowo prognoz w pierwszych trzech godzinach analizowanego zakresu, dwóch godzin dopuszczalnych i tylko jednej godziny (05:00) oznaczonej jako niedopuszczalna, kwalifikują prognozy do kategorii dopuszczalnych.

Tab. 4.1.4.1. Dopuszczalność prognoz w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, w podziale na typy dni.

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
00:00	D	ND	D	D	D	D	ND	DP	ND	ND	ND
01:00	D	ND	D	D	D	D	ND	DP	ND	ND	ND
02:00	D	ND	D	D	D	D	ND	DP	ND	ND	ND
03:00	D	ND	D	D	D	DP	ND	DP	ND	ND	ND
04:00	D	ND	D	D	D	DP	ND	DP	ND	ND	ND
05:00	ND	ND	D	D	D	ND	ND	DP	ND	ND	ND
<i>średnia</i>	<i>DP</i>	<i>ND</i>	<i>D</i>	<i>D</i>	<i>D</i>	<i>DP</i>	<i>ND</i>	<i>DP</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>

Legenda: BD: prognoza bardzo dokładna; D: prognoza dokładna (kolor zielony); DP: prognoza dopuszczalna (kolor jasnozielony); ND: prognoza niedopuszczalna (kolor ciemnozielony).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tabela 4.1.4.2 zawiera wynik przeprowadzenia oceny dopuszczalności prognoz dla metody ważonych współczynników funkcji autokorelacji cząstkowej w zakresie godzin 06:00 – 23:00. Dobrą jakość prognoz dla wskazanego zakresu uzyskuje się dla śród i czwartków, dopuszczalną dla wtorków i piątków oraz niedopuszczalną dla poniedziałków, sobót, niedziel, wszystkich dni roboczych, wszystkich dni weekendowych, Świąt Bożego Narodzenia oraz Wigilii tych Świąt.

Tab. 4.1.4.2. Dopuszczalność prognoz w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, w podziale na typy dni.

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
06:00	ND	ND	D	D	DP	ND	ND	ND	ND	ND	ND
07:00	ND	ND	DP	DP	DP	ND	ND	ND	ND	ND	ND
08:00	ND	ND	DP	DP	DP	ND	ND	ND	ND	ND	ND
09:00	ND	DP	DP	DP	DP	ND	ND	ND	ND	ND	ND
10:00	ND	DP	D	DP	DP	ND	ND	ND	ND	ND	ND
11:00	ND	DP	DP	DP	DP	ND	ND	ND	ND	ND	ND
12:00	ND	DP	DP	DP	DP	ND	ND	ND	ND	ND	ND
13:00	ND	DP	DP	DP	DP	ND	ND	ND	ND	ND	ND
14:00	ND	DP	DP	DP	DP	ND	ND	ND	ND	ND	ND
15:00	ND	DP	DP	DP	DP	ND	ND	ND	ND	ND	ND
16:00	ND	DP	D	DP	DP	ND	ND	ND	ND	ND	ND
17:00	ND	DP	D	D	DP	ND	ND	ND	ND	ND	ND
18:00	ND	DP	D	D	D	ND	ND	ND	ND	ND	ND
19:00	ND	DP	D	D	D	ND	ND	ND	ND	ND	ND
20:00	ND	DP	D	D	DP	ND	ND	ND	ND	ND	ND
21:00	ND	D	D	D	DP	ND	DP	DP	ND	ND	ND
22:00	ND	D	D	D	D	ND	DP	DP	ND	ND	ND
23:00	ND	D	D	D	D	ND	DP	DP	ND	ND	ND
<i>średnia</i>	<i>ND</i>	<i>DP</i>	<i>D</i>	<i>D</i>	<i>DP</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>	<i>ND</i>

Legenda: BD: prognoza bardzo dokładna; D: prognoza dokładna (kolor zielony); DP: prognoza dopuszczalna (kolor jasnozielony); ND: prognoza niedopuszczalna (kolor ciemnozielony).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.1.5. Analiza dopuszczalności dla dni świątecznych i niestandardowych

Ocena dopuszczalności prognoz dla poszczególnych dni świątecznych i niestandardowych (Tab. 4.1.5.1) w poszczególnych latach analizy dla godzin 00:00 – 05:00 wskazuje, że dopuszczalność otrzymywana jest dla Świąta Trzech Króli, natomiast dla Sylwestra otrzymywana jest dobra jakość prognoz w całym okresie analizy. Dla pozostałych dni świątecznych i niestandardowych uzyskiwana jest niedopuszczalność prognoz opracowywanych metodą ważonych współczynników funkcji autokorelacji cząstkowej. Dla Świąta Trzech Króli w ośmiu latach analizy zauważalne jest trzykrotne wystąpienie niedopuszczalności prognoz, czterokrotne wystąpienie dopuszczalności i jednokrotne wystąpienie dobrej jakości prognozy. Święto Trzech Króli obowiązuje w Polsce od 2011 roku, dlatego też zamiast dziesięciu lat analiza możliwa jest wyłącznie dla ośmioletniego okresu. Dobra jakość prognoz dla Sylwestra otrzymywana dzięki złożeniu trzech prognoz niedopuszczalnych, jednej dopuszczalnej, trzech o dobrej jakości i trzech o bardzo dobrej jakości.

Tabela 4.1.5.2 zawiera wyniki oceny dopuszczalności prognoz metody ważonych współczynników funkcji autokorelacji cząstkowej dla poszczególnych lat całego okresu analizy za okres godzin 06:00 – 23:00. Odnotowywana jest niedopuszczalność prognoz dla wszystkich typów dni świątecznych i niestandardowych.

Dopuszczalność prognoz wykonanych metodą ważonych współczynników funkcji autokorelacji cząstkowej dla zakresu godzin 00:00 – 05:00 dla każdego dnia świątecznego z osobna w całym dziesięcioletnim okresie analizy zawiera Tabela 4.1.5.3. Dopuszczalność prognoz odnotowywana jest dla Świąta Trzech Króli, a dla Sylwestra uzyskiwana jest dobra jakość prognoz. W odniesieniu do pozostałych dni świątecznych i niestandardowych odnotowywana jest niedopuszczalność prognoz metody ważonych współczynników funkcji autokorelacji cząstkowej.

Tab. 4.1.5.1. Dopuszczalność prognoz w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S01 do S16.

Św.	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
S01	ND	ND	ND	D	D	ND	ND	DP	ND	D	ND
S02	–	–	ND	D	DP	DP	ND	ND	DP	DP	DP
S03	ND	ND	ND	ND	ND	ND	ND	ND	ND	D	ND
S04	ND	ND	ND	ND	ND	ND	ND	D	DP	D	ND
S05	ND	ND	ND	D	ND	ND	ND	ND	ND	DP	ND
S06	ND	ND	D	ND	ND	ND	ND	D	DP	ND	ND
S07	ND	DP	DP	DP	ND	ND	ND	D	DP	D	ND
S08	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
S09	ND	ND	ND	ND	ND	ND	ND	ND	ND	DP	ND
S10	ND	ND	ND	D	ND	DP	ND	DP	D	DP	ND
S11	ND	ND	DP	ND	ND	ND	ND	D	ND	ND	ND
S12	ND	ND	ND	ND	ND	DP	ND	ND	ND	ND	ND
S13	ND	ND	ND	D	DP	ND	ND	ND	ND	BD	ND
S14	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
S15	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
S16	DP	D	D	D	ND	BD	BD	ND	ND	BD	D

Legenda: BD: prognoza bardzo dokładna; D: prognoza dokładna (kolor zielony); DP: prognoza dopuszczalna (kolor jasnozielony); ND: prognoza niedopuszczalna (kolor ciemnozielony).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.1.5.2. Dopuszczalność prognoz w godzinach 06:00 – 23:00 w horyzoncie $n+1$
dla metody ważonych współczynników funkcji autokorelacji cząstkowej
w latach 2009 – 2018, dla dni świątecznych od S01 do S16.

Św.	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
S01	ND	ND	ND	ND	ND	ND	ND	ND	ND	DP	ND
S02	–	–	ND	ND	ND	ND	ND	ND	ND	ND	ND
S03	ND	ND	ND	ND	ND	ND	ND	ND	ND	DP	ND
S04	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
S05	ND	ND	ND	ND	ND	ND	ND	ND	D	ND	ND
S06	ND	ND	ND	ND	ND	ND	ND	ND	DP	ND	ND
S07	D	DP	DP	ND	ND	ND	DP	ND	ND	ND	ND
S08	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
S09	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
S10	ND	ND	ND	ND	ND	ND	ND	DP	ND	ND	ND
S11	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
S12	ND	ND	ND	ND	D	ND	ND	ND	ND	ND	ND
S13	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
S14	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
S15	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
S16	ND	ND	ND	DP	ND	ND	ND	ND	ND	ND	ND

Legenda: BD: prognoza bardzo dokładna; D: prognoza dokładna (kolor zielony); DP: prognoza dopuszczalna (kolor jasnozielony); ND: prognoza niedopuszczalna (kolor ciemnozielony).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.1.5.3. Dopuszczalność prognoz w godzinach 00:00 – 05:00 w horyzoncie $n+1$
dla metody ważonych współczynników funkcji autokorelacji cząstkowej
w latach 2009 – 2018, dla dni świątecznych od S01 do S16.

h	S01	S02	S03	S04	S05	S06	S07	S08	S09	S10	S11	S12	S13	S14	S15	S16
00:00	D	DP	ND	ND	ND	ND	ND	ND	D	D	ND	ND	ND	ND	ND	D
01:00	D	DP	ND	ND	ND	ND	ND	ND	DP	DP	ND	ND	ND	ND	ND	D
02:00	DP	DP	ND	ND	ND	ND	ND	ND	DP	DP	ND	ND	ND	ND	ND	DP
03:00	ND	DP	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	D
04:00	ND	DP	ND	ND	ND	ND	DP	ND	ND	ND	ND	ND	ND	ND	ND	D
05:00	ND	DP	ND	ND	ND	ND	DP	ND	ND	ND	ND	ND	ND	ND	ND	DP
średnia	ND	DP	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	D

Legenda: BD: prognoza bardzo dokładna; D: prognoza dokładna (kolor zielony); DP: prognoza dopuszczalna (kolor jasnozielony); ND: prognoza niedopuszczalna (kolor ciemnozielony).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Ocena dopuszczalności prognoz metody ważonych współczynników funkcji autokorelacji cząstkowej w podziale na poszczególne dni świąteczne i dni niestandardowe w godzinach 06:00 – 23:00 (Tab. 4.1.5.4) wskazuje, że w żadnym z analizowanych dni otrzymywane prognozy nie spełniają kryterium dopuszczalności pomimo incydentalnego spełnienia kryteriów dla godzin 18:00 – 23:00 w Nowy Rok i w Święto Trzech Króli oraz dla godzin 22:00 i 23:00 dla Święta 3. Maja.

Tab. 4.1.5.4. Dopuszczalność prognoz w godzinach 06:00 – 23:00 w horyzoncie $n+1$
dla metody ważonych współczynników funkcji autokorelacji cząstkowej
w latach 2009 – 2018, dla dni świątecznych od S01 do S16.

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08	S09	S10	S11	S12	S13	S14	S15	S16
06:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
07:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
08:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
09:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
10:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
11:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
12:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
13:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
14:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
15:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
16:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
17:00	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
18:00	DP	DP	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
19:00	D	DP	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
20:00	D	DP	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
21:00	D	DP	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
22:00	DP	DP	ND	ND	ND	ND	DP	ND	ND	ND	ND	ND	ND	ND	ND	ND
23:00	DP	DP	ND	DP	ND	ND	DP	ND	ND	ND	ND	ND	ND	ND	ND	ND
<i>średnia</i>	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND

Legenda: BD: prognoza bardzo dokładna; D: prognoza dokładna (kolor zielony); DP: prognoza dopuszczalna (kolor jasnozielony); ND: prognoza niedopuszczalna (kolor ciemnozielony).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.2. Walidacja modelu ważonych współczynników funkcji autokorelacji cząstkowej – studium przypadku Krajowego Systemu Elektroenergetycznego

4.2.1. Skuteczność prognozowania PSE S.A. dla Krajowego Systemu Elektroenergetycznego

Ocena skuteczności osiągana na podstawie porównania historycznych planów BPKD publikowanych w ostatnich dwóch godzinach doby realizacji prognozy i historycznych danych o wielkości zapotrzebowania na moc elektryczną w KSE jest zaprezentowana w kolejnych tabelach. Tabela 4.2.1.1 wskazuje, że błędy prognozowania zapotrzebowania na moc w KSE we wszystkich godzinach każdego roku z osobna systematycznie maleją. Największa wartość (1,28%) odnotowana jest dla pierwszego roku analizy, natomiast najmniejsza dla ostatniego roku analizy (0,71%). Od 2010 roku przez dziewięć kolejnych lat uzyskiwany poziom błędów MAPE, wyrażonych w wartościach względnych, utrzymywał się na poziomie <1,00%, co stanowi o bardzo wysokiej jakości uzyskiwanych prognoz opracowywanych przez PSE S.A. W odniesieniu do podziału na dni tygodnia oraz dni robocze, wolne i świąteczne, uwidacznia się zróżnicowanie w osiąganych wartościach błędów MAPE. Najmniejsze wartości błędów prognoz odnotowuje się dla wtorku i środy (0,78%), największe dla dni świątecznych (1,04%), wysokie dla niedziel i poniedziałków (odpowiednio 0,88% i 0,86%). Grupa dni wolnych od pracy, ze skutecznością prognozowania na poziomie 0,84%, charakteryzowana jest jako złożenie arytmetyczne sobót oraz niedziel. W grupie dni roboczych największym wyzwaniem z punktu widzenia opracowywania prognoz są poniedziałki, które następują po sobocie i niedzieli. W analizowanej grupie

określających różne typy dni, jedynie w odniesieniu do dni świątecznych odnotowuje się efektywność na poziomie w niewielkim stopniu przekraczającym 1,00%. W pozostałych przypadkach poddanych analizie otrzymywana jest efektywność prognoz na poziomie ok. 0,80%. Podobnie jak w przypadku analizy przeprowadzonej dla pełnych lat wskazane wartości oznaczają bardzo wysoką jakość prognoz opracowywanych przez PSE S.A. w odniesieniu do prognozowania zapotrzebowania na moc elektryczną w KSE (czołowa pozycja w porównaniu do operatorów systemów elektroenergetycznych zrzeszonych w ENTSO – E).

Tab. 4.2.1.1. Skuteczność roczna prognoz oraz w podziale na typy dni i godziny doby w ramach planów BPKD wyrażona wartościami błędów MAPE, [%].

Rok	Cała doba	00:00 – 05:00	06:00 – 23:00	Dzień	Cała doba	00:00 – 05:00	06:00 – 23:00
2009	1,28	2,58	0,85	Poniedziałek	0,86	1,15	0,77
2010	0,85	0,92	0,82	Wtorek	0,78	1,01	0,71
2011	0,81	0,85	0,79	Środa	0,78	1,07	0,69
2012	0,78	0,84	0,76	Czwartek	0,81	1,04	0,73
2013	0,75	0,82	0,73	Piątek	0,81	1,00	0,75
2014	0,74	0,86	0,71	Sobota	0,81	0,88	0,78
2015	0,79	0,92	0,75	Niedziela	0,88	1,02	0,84
2016	0,75	0,85	0,71	Dni robocze	0,81	1,05	0,73
2017	0,74	0,81	0,71	Dni wolne od pracy	0,84	0,95	0,81
2018	0,71	0,79	0,68	Dni świąteczne	1,03	1,22	0,98
<i>średnia</i>	<i>0,82</i>	<i>1,02</i>	<i>0,75</i>	<i>średnia</i>	–	–	–

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Zaprezentowany poziom skuteczności prognoz został uszczegółowiony w Tabeli 4.2.1.2 i w Tabeli 4.2.1.3, które zawierają podział na godziny doby dla całego okresu analizy. W trakcie doby wyodrębnia się, ze względu na osiągnięte poziomy efektywności prognoz, cztery kilkugodzinne okresy oraz jeden zakres jednogodzinny, o porównywalnych poziomach efektywności prognoz. Pierwszy obejmuje pierwsze pięć godzin doby (00:00 – 04:00) ze średnią skutecznością za lata 2010 – 2018 na poziomie 0,97% (Tab. 4.2.1.2). Rok 2009 charakteryzuje się największymi błędami w tym pasmie (2,66%). Drugi zakres obejmuje trzy godziny, od 05:00 – 07:00 i charakteryzuje się średnią efektywnością za lata 2010 – 2018 na poziomie 1,15%. Podobnie jak w przypadku pierwszego zakresu 2009 rok charakteryzuje się największymi błędami w analizowanym pasmie (1,55%). Godzina 08:00 cechuje się odwróceniem trendu malejącej skuteczności uzyskiwanych prognoz (0,79%) i stanowi punkt przejściowy przed przejściem do czwartego zakresu godzinowego. W przypadku tego zakresu nie dochodzi do odchylenia w jakości opracowywanych prognoz dla 2009 roku, w przeciwieństwie do poprzednich dwóch zakresów, gdzie odchylenia były znaczące.

Tab. 4.2.1.2. Skuteczność prognoz w poszczególnych latach 2009 – 2018 w godzinach 00:00 – 05:00 doby w ramach planów BPKD wyrażona wartościami błędów MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
00:00	2,49	0,87	0,83	0,85	0,78	0,89	1,00	0,82	0,79	0,75	1,01
01:00	1,83	0,93	0,93	0,81	0,84	1,00	0,94	0,84	0,86	0,86	0,98
02:00	2,82	0,80	0,66	0,71	0,66	0,72	0,81	0,72	0,68	0,62	0,92
03:00	3,09	0,81	0,71	0,70	0,68	0,68	0,80	0,71	0,64	0,60	0,94
04:00	3,06	0,89	0,79	0,77	0,71	0,71	0,80	0,77	0,75	0,74	1,00
05:00	2,16	1,24	1,20	1,19	1,23	1,14	1,16	1,22	1,17	1,19	1,29
<i>średnia</i>	<i>2,58</i>	<i>0,92</i>	<i>0,85</i>	<i>0,84</i>	<i>0,82</i>	<i>0,86</i>	<i>0,92</i>	<i>0,85</i>	<i>0,82</i>	<i>0,79</i>	<i>1,02</i>

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Czwarty zakres godzinowy obejmuje przedział dziesięciu godzin od 09:00 – 18:00 i charakteryzuje się skutecznością prognozowania na poziomie 0,63%. Również w tym zakresie nie zachodzą odchylenia w efektywności prognozowania dla 2009 roku.

Tab. 4.2.1.3. Skuteczność prognoz w poszczególnych latach 2009 – 2018 w godzinach 06:00 – 23:00 doby w ramach planów BPKD wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
06:00	1,34	1,33	1,14	1,15	1,03	0,99	1,08	1,08	1,12	1,13	1,14
07:00	1,15	1,18	1,08	1,14	1,07	0,95	0,92	0,90	1,04	0,95	1,04
08:00	0,85	0,85	0,87	0,83	0,79	0,77	0,78	0,72	0,78	0,69	0,79
09:00	0,66	0,69	0,70	0,62	0,66	0,61	0,65	0,62	0,60	0,59	0,64
10:00	0,72	0,72	0,70	0,68	0,68	0,63	0,68	0,65	0,68	0,70	0,68
11:00	0,68	0,66	0,64	0,57	0,55	0,56	0,57	0,60	0,62	0,62	0,61
12:00	0,60	0,62	0,58	0,57	0,51	0,49	0,59	0,58	0,56	0,54	0,56
13:00	0,70	0,70	0,67	0,61	0,61	0,62	0,68	0,60	0,58	0,54	0,63
14:00	0,69	0,67	0,66	0,62	0,59	0,60	0,66	0,59	0,55	0,56	0,62
15:00	0,67	0,71	0,66	0,60	0,64	0,60	0,69	0,61	0,56	0,55	0,63
16:00	0,70	0,70	0,66	0,64	0,64	0,67	0,67	0,57	0,61	0,56	0,64
17:00	0,72	0,75	0,65	0,66	0,67	0,66	0,62	0,57	0,68	0,62	0,66
18:00	0,71	0,75	0,73	0,69	0,63	0,67	0,68	0,61	0,66	0,62	0,68
19:00	0,91	0,83	0,86	0,85	0,74	0,74	0,77	0,70	0,67	0,65	0,77
20:00	0,95	0,93	0,95	0,85	0,86	0,80	0,88	0,87	0,79	0,75	0,86
21:00	1,03	0,93	0,96	0,90	0,91	0,83	0,83	0,91	0,74	0,69	0,87
22:00	1,13	1,00	0,99	0,95	0,88	0,83	0,92	0,93	0,83	0,79	0,93
23:00	1,10	0,80	0,79	0,79	0,69	0,72	0,80	0,78	0,71	0,65	0,78
średnia	0,85	0,82	0,79	0,76	0,73	0,71	0,75	0,72	0,71	0,68	0,75

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Piąty i ostatni pięciogodzinny zakres godzinowy obejmuje czas od 19:00 – 23:00 i opisywany jest przez skuteczność prognozowania na poziomie 0,84%. Również w przypadku tego zakresu 2009 rok nie odznacza się odstępstwami od poziomu jakości opracowanych prognoz.

Dni tygodnia i dni charakterystyczne

Skuteczność prognoz zapotrzebowania na moc elektryczną w KSE w planach BPKD dla godzin 00:00 – 05:00 (Tabela 4.2.1.4.) w podziale na typy dni osiąga najmniejszą wartość dla sobót (0,88%), a największą osiąga dla dni Świątecznych i niestandardowych (1,22%). W soboty najmniejszym błędem (0,79%) obciążone są prognozy dla godziny 03:00, a największym (1,04%) prognozy dla godziny 01:00. W dni świąteczne najmniejszy błąd prognozowania (1,09%) dotyczy również godziny 03:00, a największy (1,39%) również dotyczy godziny 01:00.

Tab. 4.2.1.4. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ w ramach planów BPKD w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
00:00	1,04	1,02	1,07	1,05	0,96	0,90	1,00	1,03	0,95	1,31	1,10
01:00	0,99	0,89	0,99	1,01	0,96	1,04	0,99	0,97	1,02	1,39	0,88
02:00	1,00	0,93	0,96	0,88	0,87	0,83	0,97	0,93	0,90	1,12	1,18
03:00	1,04	0,96	0,98	0,92	0,90	0,79	0,98	0,96	0,89	1,09	1,20
04:00	1,11	1,00	1,03	1,00	0,96	0,82	1,07	1,02	0,95	1,15	1,28
05:00	1,69	1,23	1,38	1,40	1,33	0,89	1,11	1,41	1,00	1,23	1,32
średnia	1,15	1,01	1,07	1,04	1,00	0,88	1,02	1,05	0,95	1,22	1,16

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.2.1.5. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$
w ramach planów BPKD w latach 2009 – 2018, w podziale na typy dni,
wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
06:00	1,30	0,95	1,07	1,21	1,26	1,05	1,12	1,16	1,08	1,20	1,51
07:00	1,17	0,86	0,81	0,95	1,11	1,19	1,17	0,98	1,18	1,35	1,14
08:00	0,89	0,75	0,61	0,69	0,77	0,81	1,02	0,74	0,92	1,24	0,80
09:00	0,73	0,67	0,54	0,59	0,60	0,60	0,74	0,63	0,67	0,99	0,84
10:00	0,75	0,70	0,62	0,62	0,64	0,70	0,75	0,67	0,73	0,90	0,97
11:00	0,68	0,62	0,53	0,57	0,58	0,61	0,67	0,59	0,64	0,91	1,18
12:00	0,59	0,52	0,55	0,51	0,53	0,62	0,63	0,54	0,62	0,76	0,91
13:00	0,59	0,58	0,58	0,63	0,59	0,70	0,74	0,60	0,72	0,91	1,04
14:00	0,62	0,59	0,55	0,58	0,59	0,65	0,76	0,58	0,71	0,83	0,73
15:00	0,64	0,60	0,55	0,59	0,63	0,67	0,73	0,60	0,70	0,94	1,06
16:00	0,64	0,62	0,59	0,61	0,63	0,67	0,72	0,62	0,69	0,86	1,01
17:00	0,63	0,60	0,59	0,65	0,65	0,70	0,80	0,62	0,75	0,87	0,70
18:00	0,64	0,63	0,60	0,66	0,63	0,74	0,82	0,63	0,78	0,81	0,97
19:00	0,74	0,73	0,75	0,73	0,75	0,85	0,86	0,74	0,85	1,01	0,77
20:00	0,89	0,88	0,88	0,86	0,73	0,90	0,89	0,85	0,89	0,99	0,76
21:00	0,84	0,86	0,92	0,99	0,76	0,87	0,90	0,87	0,88	0,90	0,76
22:00	0,79	0,90	0,88	0,93	1,03	0,97	0,97	0,91	0,97	1,17	1,00
23:00	0,72	0,67	0,74	0,72	1,04	0,79	0,81	0,78	0,80	0,96	0,83
średnia	0,77	0,71	0,69	0,73	0,75	0,78	0,84	0,73	0,81	0,98	0,94

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Skuteczność prognoz zapotrzebowania na moc elektryczną w KSE w planach BPKD dla godzin 06:00 – 23:00 (Tab. 4.2.1.5) w podziale na typy osiąga najmniejszą wartość dla śród (0,69%), a największą dla dni Świątecznych i niestandardowych (0,98%). W środy najmniejszym błędem (0,53%) obciążone są prognozy dla godziny 11:00, a największym (1,07%) prognozy dla godziny 06:00. W dni świąteczne najmniejszy błąd prognozowania (0,76%) dotyczy godziny 12:00, a największy (1,35%) również dotyczy godziny 07:00.

Dni świąteczne i dni niestandardowe

Skuteczność prognoz zapotrzebowania na moc elektryczną w KSE w planach BPKD dla godzin 00:00 – 05:00 (Tab. 4.2.1.6 i Tab. 4.2.1.7) dla dni świątecznych i niestandardowych osiąga najmniejszą wartość dla Święta Trzech Króli (0,83%), a największą osiąga dla Święta Wniebowzięcia NMP (1,61%). Dla Święta Trzech Króli najmniejszym błędem (0,68%) obciążone są prognozy dla godziny 03:00, a największym (1,03%) prognozy dla godziny 05:00. W przypadku Święta Wniebowzięcia NMP najmniejszy błąd prognozowania (1,03%) dotyczy godziny 05:00, a największy (1,84%) dotyczy godziny 01:00.

Tab. 4.2.1.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$
w ramach planów BPKD w latach 2009 – 2018, dla dni świątecznych od S01 do S08,
wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
00:00	1,14	0,99	1,35	0,85	1,17	0,81	1,77	1,40
01:00	0,98	0,87	1,22	0,88	1,24	0,73	1,12	1,70
02:00	0,66	0,70	1,42	1,04	0,73	1,09	1,02	1,55
03:00	0,65	0,68	1,05	1,07	0,96	0,99	0,96	1,62
04:00	0,72	0,74	0,94	1,03	1,29	0,89	1,09	1,37
05:00	0,95	1,03	1,90	1,40	1,30	1,35	1,34	0,73
średnia	0,85	0,83	1,31	1,04	1,11	0,98	1,21	1,40

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.2.1.7. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ w ramach planów BPKD w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
00:00	1,62	1,72	1,12	1,55	0,88	1,45	1,54	1,05
01:00	1,31	1,84	1,30	1,24	1,10	1,41	1,30	1,32
02:00	0,84	1,60	1,19	0,88	1,18	1,72	0,92	0,96
03:00	1,18	1,67	0,96	0,70	1,20	1,68	0,73	1,22
04:00	1,42	1,77	0,84	0,96	1,28	1,66	1,05	1,05
05:00	1,49	1,03	1,25	0,98	1,32	1,49	1,24	1,28
<i>średnia</i>	1,31	1,61	1,11	1,05	1,16	1,57	1,13	1,15

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Skuteczność prognoz zapotrzebowania na moc elektryczną w KSE w planach BPKD dla godzin 06:00 – 23:00 (Tab. 4.2.1.8 i Tab. 4.2.1.9) dla dni świątecznych i niestandardowych osiąga najmniejszą wartość dla Święta Trzech Króli (0,71%), a największą osiąga dla Nowego Roku (1,09%). Dla Święta Trzech Króli najmniejszym błędem (0,54%) obciążone są prognozy dla godziny 11:00 i 15:00, a największym (1,04%) prognozy dla godziny 07:00. W przypadku Nowego Roku najmniejszy błąd prognozowania (0,64%) dotyczy godziny 19:00, a największy (1,65%) dotyczy godziny 08:00.

Tab. 4.2.1.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ w ramach planów BPKD w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
06:00	1,32	1,01	0,95	1,21	1,09	1,35	1,17	1,23
07:00	1,39	1,04	1,38	1,78	0,78	1,49	1,29	2,33
08:00	1,65	0,84	1,00	1,39	0,88	0,85	0,95	1,74
09:00	1,17	0,55	0,98	0,82	0,67	0,72	1,37	1,61
10:00	1,08	0,59	0,91	0,49	0,88	0,75	1,00	1,10
11:00	1,10	0,54	0,96	0,78	0,73	0,49	1,14	1,14
12:00	0,95	0,55	0,87	0,76	0,64	0,51	0,96	0,90
13:00	1,11	0,67	0,60	0,70	0,94	0,63	1,03	0,74
14:00	1,16	0,60	0,63	1,14	1,00	0,72	0,95	0,65
15:00	1,63	0,54	0,69	0,72	0,91	0,73	0,63	1,07
16:00	0,83	0,57	0,88	1,02	0,81	0,68	0,83	0,80
17:00	0,97	0,66	0,64	0,75	0,91	0,58	0,88	0,52
18:00	0,66	0,68	0,91	0,97	0,90	0,70	0,90	0,66
19:00	0,64	0,71	1,56	1,70	0,83	0,82	0,76	0,76
20:00	1,06	0,82	0,72	1,04	1,21	1,03	1,21	1,12
21:00	1,03	0,80	1,11	0,66	0,79	1,03	1,19	0,90
22:00	1,07	0,93	0,91	0,78	1,38	0,94	1,29	1,06
23:00	0,79	0,71	0,86	0,96	0,89	1,27	1,44	0,91
<i>średnia</i>	1,09	0,71	0,92	0,98	0,90	0,85	1,05	1,07

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.2.1.9. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ w ramach planów BPKD w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
06:00	1,31	1,03	1,14	0,98	1,51	1,62	1,15	1,61
07:00	1,37	1,47	1,58	1,20	1,14	1,30	0,95	1,76
08:00	1,34	1,01	1,41	1,12	0,80	1,05	1,43	1,44
09:00	0,97	0,75	0,90	0,81	0,84	0,90	0,93	0,71
10:00	0,86	1,12	0,64	0,95	0,97	0,91	0,81	1,01
11:00	0,88	0,70	0,88	1,11	1,18	0,81	0,92	0,80
12:00	0,51	0,69	0,68	0,91	0,91	0,80	0,55	0,76
13:00	0,92	0,73	1,15	0,81	1,04	1,24	0,84	0,66
14:00	0,86	0,59	0,41	1,00	0,73	0,97	0,81	0,76
15:00	0,57	0,91	0,85	1,19	1,06	0,69	1,37	1,23
16:00	0,66	0,83	1,09	0,82	1,01	0,67	1,30	0,71
17:00	0,65	0,94	1,30	1,47	0,70	0,67	0,61	0,76
18:00	0,87	0,88	0,92	0,87	0,97	0,48	0,55	0,91
19:00	0,65	1,84	1,08	0,79	0,77	0,82	0,65	1,17
20:00	1,16	1,10	0,90	0,84	0,76	0,72	0,70	1,02
21:00	1,15	1,05	0,99	0,82	0,76	0,60	0,66	1,16
22:00	1,92	1,50	1,06	1,14	1,00	0,86	1,02	0,84
23:00	1,13	1,42	0,53	0,89	0,83	0,85	0,87	0,53
<i>średnia</i>	<i>0,99</i>	<i>1,03</i>	<i>0,97</i>	<i>0,98</i>	<i>0,94</i>	<i>0,89</i>	<i>0,90</i>	<i>0,99</i>

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.2.2. Skuteczność prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej

Skuteczność prognozowania z zastosowaniem metody ważonych współczynników funkcji autokorelacji cząstkowej (Tab. 4.2.2.1) z wykorzystaniem danych dla KSE wskazuje, że dla całej doby pierwszy i ostatni rok analizy charakteryzują się największymi błędami prognoz. Dla danych z 2009 roku jakość prognoz osiąga poziom 8,38%, natomiast w 2018 roku 8,73%. Najmniejszy błąd prognozy dla całej doby dla pełnego roku analizy osiągany jest na poziomie 7,85% dla 2011 roku. Od 2012 roku skuteczność prognoz cyklicznie rośnie, z niewielkim odchyleniem dla tego trendu mającym miejsce w 2017 roku. W odniesieniu do podziału na dni tygodnia oraz dni robocze, wolne i świąteczne uwidacznia się zróżnicowanie w osiągniętych wartościach błędów MAPE. Najmniejsze wartości błędów prognoz zauważalne są dla czwartków (3,64%), największe dla dni świątecznych (21,07%), wysokie dla poniedziałków, niedziel i sobót – odpowiednio 16,23%, 12,38% i 11,45%. Grupa dni wolnych od pracy z efektywnością prognozowania na poziomie 11,91% charakteryzowana jest jako średnia arytmetyczna sobót oraz niedziel. W grupie dni roboczych najtrudniejsze do prognozowania są dni świąteczne i dni niestandardowe oraz poniedziałki, które następują po sobocie i niedzieli. W analizowanej grupie określających różne typy dni, jedynie w odniesieniu do śród, czwartków i piątków odnotowuje się jakość na poziomie poniżej 5% czyli odpowiednio 3,59%, 3,64% i 4,03%. W pozostałych przypadkach poddanych analizie uzyskiwana jest skuteczność prognoz na poziomie ok. 6,50%, na poziomie ok. 12,00%.

Tab. 4.2.2.1. Skuteczność roczna prognoz oraz w podziale na typy dni i godziny doby dla metody ważonych współczynników funkcji autokorelacji cząstkowej, wyrażona wartościami błędu MAPE, [%].

Rok	Cała doba	00:00 – 05:00	06:00 – 23:00	Dzień	Cała doba	00:00 – 05:00	06:00 – 23:00
2009	8,38	6,22	9,10	Poniedziałek	16,23	4,13	20,26
2010	8,01	5,65	8,80	Wtorek	6,58	11,18	5,04
2011	7,85	5,55	8,61	Środa	3,59	3,10	3,75
2012	8,14	5,61	8,98	Czwartek	3,64	2,94	3,87
2013	8,27	5,64	9,15	Piątek	4,03	3,10	4,34
2014	8,29	5,76	9,13	Sobota	11,45	4,59	13,73
2015	8,39	5,79	9,26	Niedziela	12,38	11,42	12,70
2016	8,43	5,94	9,26	Dni robocze	6,81	4,89	7,45
2017	8,22	5,67	9,07	Dni wolne od pracy	11,91	8,00	13,22
2018	8,73	5,98	9,65	Dni świąteczne	21,07	11,97	24,10
<i>średnia</i>	<i>8,27</i>	<i>5,78</i>	<i>9,10</i>	<i>średnia</i>	-	-	-

Legenda: kolor zielony: prognoza dokładna (D); kolor jasnozielony (prognoza dopuszczalna).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Poziom skuteczności uzyskiwanych prognoz został uszczegółowiony w Tabeli 4.2.2.2, która zawiera podział na godziny doby dla całego 10 – letniego okresu analizy. W trakcie doby wyodrębnia się cztery zakresy godzinowe, ze względu na osiągnięte poziomy efektywności prognoz. Pierwszy poziom obejmuje pierwsze sześć godzin doby (00:00 – 05:00) ze średnią jakością za lata 2010 – 2018 na poziomie 5,78%. Rok 2009 wskazuje na największe błędy w tym pasmie (6,22%).

Tab. 4.2.2.2. Skuteczność prognoz w poszczególnych latach 2009 – 2018 dla godzin 00:00 – 05:00 dla metody ważonych współczynników funkcji autokorelacji cząstkowej, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
00:00	5,79	5,56	5,28	5,52	5,49	5,54	5,52	5,70	5,38	5,64	5,54
01:00	5,93	5,36	5,18	5,34	5,25	5,38	5,43	5,59	5,22	5,50	5,42
02:00	6,05	5,32	5,22	5,24	5,20	5,30	5,36	5,56	5,15	5,46	5,39
03:00	6,11	5,47	5,39	5,34	5,39	5,53	5,55	5,76	5,46	5,74	5,57
04:00	6,35	5,63	5,62	5,51	5,65	5,83	5,87	5,96	5,86	6,15	5,84
05:00	7,11	6,53	6,58	6,70	6,84	6,99	6,98	7,03	6,92	7,36	6,90
<i>średnia</i>	<i>6,22</i>	<i>5,65</i>	<i>5,55</i>	<i>5,61</i>	<i>5,64</i>	<i>5,76</i>	<i>5,79</i>	<i>5,93</i>	<i>5,67</i>	<i>5,98</i>	<i>5,78</i>

Legenda: kolor jasnozielony (prognoza dopuszczalna).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Drugi zakres obejmuje dziewięć godzin (06:00 i przedział od 07:00 do 09:00) i charakteryzuje się średnią skutecznością za lata 2010 – 2018 na poziomie 9,74% (Tab. 4.2.2.3). W przeciwieństwie do pierwszego zakresu rokiem o największych błędach prognoz w drugim zakresie jest 2018 rok (10,35%). W godzinach od 10:00 do 17:00 utrzymywany jest stały poziom wartości błędów prognoz. Poziom ten opisywany jest przedziałem od 8,91% (17:00) do 9,94% (15:00). Godzina 06:00 ze średnim błędem prognoz na poziomie 10,38%, włączona do drugiego zakresu stanowi utrzymanie trendu, jednakże rozpoczyna efekt znaczących przyrostów błędów prognoz, których szczyt osiągnięty jest w trzecim zakresie godzinowym. Trzeci zakres godzin (07:00 – 09:00) określany jest przez efektywność prognoz dla całego okresu analizy na poziomie 11,70%. Pierwsza godzina z tego zakresu charakteryzowana jest przez największy poziom błędów na poziomie 12,34%. W godzinach 08:00 i 09:00 dochodzi do spadku wartości błędów prognoz do poziomu odpowiednio 12,00% i 10,76%. Czwarty zakres godzinowy obejmuje wyłącznie godzinę 18:00 i charakteryzowany jest jakością prognoz na poziomie

8,14%. Piąty i ostatni przedział godzinowy, ze względu na osiąganą skuteczność za poszczególne lata analizy, obejmuje godziny od 19:00 do godziny 23:00. Średnia efektywność prognozowania w tym zakresie kształtuje się na poziomie 9,10%. Analiza poszczególnych godzin tego zakresu wskazuje na najmniejsze wartości błędów osiągnięte dla godziny 23:00 (5,62%), a największe dla godziny 19:00 (7,63%).

Tab. 4.2.2.3. Skuteczność prognoz w poszczególnych latach 2009 – 2018 dla godzin 06:00 – 23:00 dla metody ważonych współczynników funkcji autokorelacji cząstkowej, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
06:00	9,82	9,96	9,96	10,36	10,58	10,69	10,66	10,46	10,41	10,90	10,38
07:00	12,13	11,86	11,82	12,25	12,55	12,68	12,61	12,33	12,26	12,86	12,34
08:00	12,11	11,50	11,34	11,83	12,10	12,21	12,25	11,99	11,99	12,69	12,00
09:00	10,95	10,41	10,11	10,66	10,83	10,84	10,98	10,78	10,71	11,32	10,76
10:00	9,96	9,49	9,15	9,59	9,77	9,70	9,96	9,84	9,73	10,33	9,75
11:00	10,02	9,49	9,17	9,67	9,80	9,78	9,99	10,02	9,85	10,50	9,83
12:00	10,03	9,40	9,17	9,63	9,80	9,78	10,02	10,08	9,83	10,46	9,82
13:00	9,97	9,30	9,16	9,55	9,74	9,67	9,94	9,96	9,74	10,37	9,74
14:00	9,94	9,35	9,22	9,65	9,74	9,80	9,96	10,04	9,84	10,38	9,79
15:00	9,99	9,46	9,32	9,82	9,95	9,96	10,18	10,16	9,95	10,61	9,94
16:00	9,50	9,20	9,01	9,47	9,55	9,52	9,66	9,70	9,48	10,13	9,52
17:00	9,00	8,63	8,45	8,90	8,96	8,84	9,03	9,03	8,82	9,44	8,91
18:00	8,16	7,99	7,77	8,02	8,17	8,07	8,24	8,26	8,07	8,65	8,14
19:00	7,53	7,50	7,23	7,42	7,65	7,62	7,74	7,79	7,60	8,26	7,63
20:00	7,10	7,13	6,96	7,05	7,34	7,31	7,42	7,45	7,18	7,87	7,28
21:00	6,41	6,42	6,32	6,44	6,68	6,64	6,73	6,93	6,57	7,09	6,62
22:00	5,52	5,69	5,51	5,69	5,83	5,71	5,77	6,06	5,67	6,04	5,75
23:00	5,62	5,65	5,38	5,61	5,64	5,56	5,61	5,81	5,50	5,81	5,62
<i>średnia</i>	<i>9,10</i>	<i>8,80</i>	<i>8,61</i>	<i>8,98</i>	<i>9,15</i>	<i>9,13</i>	<i>9,26</i>	<i>9,26</i>	<i>9,07</i>	<i>9,65</i>	<i>9,10</i>

Legenda: kolor jasnozielony (prognoza dopuszczalna).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Dni tygodnia, dni świąteczne i dni niestandardowe

Skuteczność prognoz zapotrzebowania na moc elektryczną w KSE z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.2.2.4) w podziale na typy osiąga najmniejszą wartość dla czwartków (2,94%), a największą osiąga dla dni Świątecznych i niestandardowych (11,97%). W czwartki najmniejszym błędem (2,85%) obciążone są prognozy dla godziny 00:00, a największym (3,06%) prognozy dla godziny 05:00. W dni świąteczne najmniejszy błąd prognozowania (10,56%) dotyczy również godziny 00:00, a największy (14,91%) również dotyczy godziny 05:00.

Tab. 4.2.2.4. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla modelu ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
00:00	4,00	11,89	3,29	2,85	2,86	3,22	10,70	4,98	6,96	10,56	7,40
01:00	3,08	11,48	3,21	2,90	2,95	3,46	10,86	4,72	7,16	10,69	9,38
02:00	2,64	11,18	3,15	2,93	3,00	3,73	11,11	4,58	7,42	11,07	10,33
03:00	2,74	11,30	3,07	2,96	3,12	4,25	11,59	4,63	7,92	11,83	11,73
04:00	3,82	11,07	2,94	2,96	3,23	5,09	11,80	4,80	8,44	12,73	12,96
05:00	8,53	10,14	2,92	3,06	3,45	7,80	12,43	5,62	10,12	14,91	15,30
<i>średnia</i>	<i>4,13</i>	<i>11,18</i>	<i>3,10</i>	<i>2,94</i>	<i>3,10</i>	<i>4,59</i>	<i>11,42</i>	<i>4,89</i>	<i>8,00</i>	<i>11,97</i>	<i>11,18</i>

Legenda: rob.: dni robocze; wee.: Weekend; Św.: dni świąteczne ruchome i nieruchome; Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, kolor zielony: prognoza dokładna (D); kolor jasnozielony (prognoza dopuszczalna).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.2.2.5. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla modelu ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	<i>pon.</i>	<i>wt.</i>	<i>śr.</i>	<i>czw.</i>	<i>pt.</i>	<i>sob.</i>	<i>niedz.</i>	<i>rob.</i>	<i>wee.</i>	<i>Św.</i>	<i>Wig.</i>
06:00	20,72	8,22	3,66	3,95	4,39	15,42	16,29	8,19	15,86	24,34	23,29
07:00	27,27	7,19	4,34	4,53	5,27	18,95	18,77	9,72	18,86	30,46	29,39
08:00	27,50	6,07	4,40	4,55	5,28	16,80	19,39	9,56	18,09	31,52	27,49
09:00	24,70	5,21	4,15	4,27	4,82	13,73	18,40	8,63	16,07	30,22	23,10
10:00	22,01	4,91	3,98	4,10	4,50	11,87	16,86	7,90	14,36	28,71	20,53
11:00	22,19	4,98	4,06	4,21	4,59	12,33	16,42	8,01	14,38	28,67	21,20
12:00	22,26	5,04	4,10	4,20	4,61	13,19	15,31	8,04	14,25	27,99	21,40
13:00	22,13	5,02	4,09	4,13	4,56	13,80	14,43	7,99	14,11	27,40	21,00
14:00	22,28	5,13	4,14	4,17	4,63	14,89	13,29	8,07	14,09	27,14	20,94
15:00	22,53	5,17	4,13	4,21	4,62	15,35	13,56	8,13	14,46	27,76	20,06
16:00	21,03	5,08	3,93	4,06	4,34	14,78	13,41	7,69	14,10	26,11	20,94
17:00	19,41	4,92	3,75	3,92	4,15	14,17	12,04	7,23	13,10	23,76	29,94
18:00	17,60	4,68	3,54	3,76	3,87	13,13	10,37	6,69	11,75	21,62	36,93
19:00	16,62	4,48	3,38	3,61	3,88	13,03	8,42	6,39	10,73	20,03	39,55
20:00	16,30	4,15	3,15	3,34	4,02	12,78	7,20	6,20	9,99	18,12	36,84
21:00	15,23	3,67	3,03	3,05	4,01	12,00	5,36	5,80	8,68	15,28	29,87
22:00	12,74	3,45	2,88	2,81	3,39	10,50	4,45	5,06	7,48	12,65	22,66
23:00	12,13	3,41	2,78	2,81	3,13	10,51	4,54	4,85	7,53	12,07	18,82
<i>średnia</i>	<i>20,26</i>	<i>5,04</i>	<i>3,75</i>	<i>3,87</i>	<i>4,34</i>	<i>13,73</i>	<i>12,70</i>	<i>7,45</i>	<i>13,22</i>	<i>24,10</i>	<i>25,77</i>

Legenda: rob.: dni robocze; wee.: Weekend; Św.: dni świąteczne ruchome i nieruchome; Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, kolor zielony: prognoza dokładna (D); kolor jasnozielony (prognoza dopuszczalna).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Skuteczność prognoz zapotrzebowania na moc elektryczną w KSE z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.2.2.5) w podziale na typy osiąga najmniejszą wartość dla śród (3,75%), a największą osiąga dla Wigilii Świąt Bożego Narodzenia (25,77%). W środy najmniejszym błędem (2,78%) obciążone są prognozy dla godziny 23:00, a największym (4,40%) prognozy dla godziny 08:00. W Wigilię Świąt Bożego Narodzenia najmniejszy błąd prognozowania (18,82%) dotyczy godziny 23:00, a największy (39,55%) dotyczy godziny 19:00.

Dni świąteczne i dni niestandardowe

Skuteczność prognoz zapotrzebowania na moc elektryczną w KSE z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.2.2.6 i Tab. 4.2.2.7) dla dni świątecznych i niestandardowych osiąga najmniejszą wartość dla Sylwestra (3,91%), a największą osiąga dla pierwszego dnia Świąt Bożego Narodzenia (24,17%). Dla Święta Sylwestra najmniejszym błędem (3,67%) obciążone są prognozy dla godziny 04:00, a największym (4,19%) prognozy dla godziny 05:00. W przypadku pierwszego dnia Świąt Bożego Narodzenia najmniejszy błąd prognozowania (19,90%) dotyczy godziny 00:00, a największy (29,80%) dotyczy godziny 05:00.

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.2.2.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla modelu ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
00:00	3,20	4,21	20,54	10,99	8,03	14,62	7,69	11,42
01:00	3,17	4,00	20,25	10,67	8,18	13,87	7,36	11,92
02:00	4,68	4,04	21,15	8,95	8,90	13,62	6,35	12,26
03:00	6,99	4,09	22,25	7,39	9,50	13,41	6,09	13,03
04:00	9,90	4,11	21,82	6,88	11,74	13,98	5,62	14,85
05:00	12,23	4,85	19,42	6,98	16,41	15,28	4,78	15,94
<i>średnia</i>	6,70	4,22	20,91	8,64	10,46	14,13	6,31	13,24

Legenda: kolor zielony: prognoza dokładna (D); kolor jasnozielony (prognoza dopuszczalna).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.2.2.7. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla modelu ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
00:00	2,87	3,95	9,83	8,80	7,40	19,90	20,86	3,94
01:00	4,09	4,22	10,53	10,15	9,38	20,60	18,97	3,70
02:00	5,58	4,76	10,75	10,47	10,33	22,86	18,49	4,00
03:00	7,29	6,35	11,62	11,53	11,73	24,99	18,07	3,99
04:00	9,33	7,70	13,27	12,56	12,96	26,87	16,97	3,67
05:00	16,14	12,09	18,05	15,81	15,30	29,80	17,62	4,19
<i>średnia</i>	7,55	6,51	14,13	11,55	11,18	24,17	18,50	3,91

Legenda: kolor zielony: prognoza dokładna (D); kolor jasnozielony (prognoza dopuszczalna).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Skuteczność prognoz zapotrzebowania na moc elektryczną w KSE z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.2.2.8 i Tab. 4.2.2.9) dla dni świątecznych i niestandardowych osiąga najmniejszą wartość dla Święta Trzech Króli (6,79%), a największą osiąga dla pierwszego dnia Świąt Bożego Narodzenia (43,90%). Dla Święta Trzech Króli najmniejszym błędem (4,05%) obciążone są prognozy dla godziny 23:00, a największym (9,50%) prognozy dla godziny 07:00. W przypadku pierwszego dnia Świąt Bożego Narodzenia najmniejszy błąd prognozowania (23,15%) dotyczy godziny 23:00, a największy (55,98%) dotyczy godziny 08:00.

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.2.2.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
06:00	18,10	7,80	24,97	7,32	28,79	20,23	11,68	21,10
07:00	25,03	9,50	27,45	6,62	34,26	22,59	16,80	24,35
08:00	32,17	9,33	28,70	7,26	31,80	20,57	16,70	24,85
09:00	33,83	8,28	33,38	9,65	27,45	17,68	15,41	23,92
10:00	31,66	7,43	37,77	11,05	24,41	15,30	13,33	22,44
11:00	27,31	7,29	39,46	10,11	24,79	16,04	13,01	22,19
12:00	22,59	7,21	38,54	10,28	25,12	15,78	12,82	21,34
13:00	20,09	7,22	37,64	12,24	24,68	14,99	12,84	20,53
14:00	17,92	7,22	35,09	14,27	25,51	14,44	12,93	19,21
15:00	17,84	7,43	35,48	14,74	26,77	14,92	13,61	19,95
16:00	14,39	7,03	35,82	15,58	27,06	14,39	13,07	20,32
17:00	8,53	6,41	34,46	14,14	26,00	13,45	11,50	18,93
18:00	4,85	5,90	33,68	12,77	24,24	12,02	9,35	16,95
19:00	3,67	5,59	29,66	12,18	23,32	11,47	8,11	14,35
20:00	3,57	5,29	24,16	8,92	22,34	11,73	8,97	11,89
21:00	3,88	4,89	19,08	7,30	17,84	10,01	8,11	7,97
22:00	4,52	4,24	15,81	6,42	14,97	9,02	5,49	6,36
23:00	5,99	4,05	12,77	5,61	14,93	8,19	5,14	6,51
średnia	16,44	6,79	30,22	10,36	24,68	14,60	11,60	17,95

Legenda: kolor zielony: prognoza dokładna (D); kolor jasnozielony (prognoza dopuszczalna).

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.2.2.9. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
06:00	34,47	23,84	32,61	28,04	23,29	41,73	25,28	8,81
07:00	43,53	29,44	39,52	37,01	29,39	52,74	33,23	13,54
08:00	41,98	29,52	39,31	36,20	27,49	55,98	38,39	15,11
09:00	38,27	27,44	38,71	31,32	23,10	53,32	35,97	13,07
10:00	35,98	25,98	39,67	26,85	20,53	49,57	32,47	11,33
11:00	38,01	26,80	43,36	25,81	21,20	49,51	30,56	11,47
12:00	37,37	27,62	44,45	25,21	21,40	48,55	29,12	11,34
13:00	36,01	27,31	43,25	24,00	21,00	48,55	28,64	10,94
14:00	36,46	27,37	42,36	24,02	20,94	48,54	28,55	10,64
15:00	38,41	28,17	41,65	24,38	20,06	48,92	30,14	10,52
16:00	38,51	28,12	33,43	21,98	20,94	46,57	25,74	8,34
17:00	36,56	26,35	30,27	22,22	29,94	45,27	17,22	7,44
18:00	33,20	24,17	31,35	20,74	36,93	42,82	11,12	7,79
19:00	32,14	22,19	30,22	20,53	39,55	40,38	8,75	11,65
20:00	31,14	18,89	28,06	19,23	36,84	36,84	8,30	16,60
21:00	25,83	16,95	24,16	16,82	29,87	31,79	7,19	16,39
22:00	20,55	14,06	20,88	13,29	22,66	25,92	6,60	11,75
23:00	19,62	13,29	20,17	12,75	18,82	23,15	8,15	7,06
średnia	34,34	24,31	34,64	23,91	25,77	43,90	22,52	11,32

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.2.3. Skuteczność modelu ważonych współczynników a skuteczność PSE S.A. dla Krajowego Systemu Elektroenergetycznego

Indywidualne analizy skuteczności prognozowania pomiędzy metodą ważonych współczynników funkcji autokorelacji cząstkowej i skutecznością osiąganą przez PSE S.A. pozwalają na bezpośrednie porównanie uzyskiwanych wyników. Szczegółowy wykaz będący rezultatem porównania zamieszczony jest w Tabeli 4.2.3.1. Degresja efektywności uzyskiwanych prognoz rokrocznie za cały okres analizy kształtuje się na poziomie 7,45%. Największa degresja jakości prognozowania dla całych dób w ujęciu rocznym osiągana jest dla 2018 roku (8,02%). Najmniejszą degresją skuteczności prognozowania charakteryzowały się pierwsze trzy lata okresu analizy (7,10%; 7,16%, 7,04%). W tym okresie dynamika przyrostów zapotrzebowania na moc elektryczną w KSE była niewielka. Naturalną przyczyną dla takiego wyniku jest również fakt doskonalenia metodyki prognozowania przez PSE S.A. stąd początek okresu analizy pozwalał na osiągnięcie korzystniejszych wyników prognoz.

Taka sama analiza porównawcza dla pierwszych sześciu godzin doby w ujęciu rocznym wskazuje na analogiczne wnioski. Pierwszy rok analizy charakteryzuje się najmniejszą degresją jakości prognozowania (3,65%). Ostatni rok analizy w tym przedziale godzinowym charakteryzuje się degresją jakości prognozowania na poziomie 5,18%. Degresja skuteczności opracowywanych prognoz rokrocznie za cały okres analizy kształtuje się na poziomie 4,75%. W odniesieniu do pozostałych godzin doby, czyli przedziału od godziny 06:00 do godziny 23:00, degresja efektywności opracowywanych prognoz rokrocznie za cały okres analizy osiąga poziom 8,35%. Najmniejszą degresją skuteczności prognozowania charakteryzują się lata 2010 i 2011 (7,98% i 7,82%). Największa degresja jakości prognozowania odnotowywana jest dla 2018 roku (8,97%). Całodobowa analiza porównawcza skuteczności wskazuje, że zastosowanie opracowanej metody ważonych współczynników funkcji autokorelacji cząstkowej dla danych historycznych KSE dla poszczególnych typów dni nie skutkuje poprawą efektywności prognoz. Największa degresja jakości prognozowania osiągana jest dla dni świątecznych (20,03%). Najmniejszą degresją skuteczności prognozowania charakteryzują się środy, czwartki i piątki (2,80%; 2,83%, 3,22%).

Analiza porównawcza efektywności prognozowania dla pierwszych sześciu godzin doby wskazuje, że najmniejszą degresją efektywności prognozowania charakteryzują się środy, czwartki i piątki (2,03%; 1,90% i 2,10%) co wynika z niewielkich błędów osiągniętych dla metody ważonych współczynników funkcji autokorelacji cząstkowej. Największa degresja jakości prognozowania odnotowywana jest dla dni świątecznych i niestandardowych (10,75%), dla niedziel (10,39%) i dla wtorków (10,17%). Najmniejszą degresją jakości prognozowania dla pozostałych osiemnastu godzin doby, podobnie jak w przypadku pierwszych sześciu godzin doby, charakteryzują się środy, czwartki i piątki (3,06%; 3,14% i 3,59%). Największa degresja skuteczności prognozowania odnotowywana jest dla dni świątecznych i niestandardowych (23,13%) i dla poniedziałków (19,49%).

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.2.3.1. Skuteczność roczna prognoz oraz w podziale na typy dni i godziny doby dla metody ważonych współczynników funkcji autokorelacji cząstkowej w porównaniu do prognozowania dla KSE, wyrażona wartościami błędu MAPE, [%].

Rok	Cała doba	00:00 – 05:00	06:00 – 23:00	Dzień	Cała doba	00:00 – 05:00	06:00 – 23:00
2009	7,10	3,65	8,25	Poniedziałek	15,36	2,99	19,49
2010	7,16	4,72	7,98	Wtorek	5,80	10,17	4,34
2011	7,04	4,69	7,82	Środa	2,80	2,03	3,06
2012	7,35	4,77	8,21	Czwartek	2,83	1,90	3,14
2013	7,52	4,82	8,42	Piątek	3,22	2,10	3,59
2014	7,54	4,90	8,42	Sobota	10,64	3,71	12,95
2015	7,60	4,87	8,52	Niedziela	11,49	10,39	11,86
2016	7,68	5,09	8,55	Dni robocze	6,00	3,84	6,73
2017	7,48	4,85	8,36	Dni wolne od pracy	11,07	7,05	12,41
2018	8,02	5,18	8,97	Dni świąteczne	20,03	10,75	23,13
<i>średnia</i>	7,45	4,75	8,35	<i>średnia</i>	–	–	–

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Skuteczność prognoz zapotrzebowania na moc elektryczną w KSE z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.2.3.2) w poszczególnych latach analizy jest niższa w porównaniu do skuteczności prognoz opracowywanych w ramach planów BPKD. Degresja jakości prognozowania za cały okres analizy wynosi 4,75%. Najmniejsza degresja jakości prognozowania dotyczy godziny 01:00 (4,41%), a największa dotyczy godziny 05:00 (5,62%). Analiza poszczególnych lat wskazuje, że najmniejszą degresją uzyskiwanych prognoz charakteryzuje się 2009 rok (3,65%), a największą 2018 rok (5,18%).

Tab. 4.2.3.2. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
00:00	3,96	4,63	4,36	4,71	4,65	4,54	4,58	4,86	4,52	4,79	4,56
01:00	3,44	4,49	4,35	4,49	4,47	4,49	4,43	4,77	4,43	4,76	4,41
02:00	3,23	4,52	4,56	4,53	4,54	4,58	4,55	4,84	4,48	4,84	4,47
03:00	3,02	4,66	4,67	4,64	4,71	4,84	4,75	5,06	4,82	5,14	4,63
04:00	3,29	4,74	4,83	4,74	4,94	5,12	5,06	5,19	5,12	5,42	4,84
05:00	4,95	5,29	5,38	5,51	5,61	5,85	5,82	5,81	5,75	6,17	5,62
<i>średnia</i>	3,65	4,72	4,69	4,77	4,82	4,90	4,87	5,09	4,85	5,18	4,75

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Skuteczność prognoz zapotrzebowania na moc elektryczną w KSE z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.2.3.3) w poszczególnych latach analizy jest niższa w porównaniu do skuteczności prognoz opracowywanych w ramach planów BPKD. Degresja efektywności prognozowania za cały okres analizy wynosi 8,35%. Najmniejsza degresja efektywności prognozowania dotyczy godziny 22:00 (4,82%), a największa dotyczy godziny 07:00 (11,30%). Analiza poszczególnych lat wskazuje, że najmniejszą degresją opracowywanych prognoz charakteryzuje się 2011 rok (7,82%), a największą 2018 rok (8,97%).

Tab. 4.2.3.3. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w poszczególnych latach 2009 - 2018, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009-2018
06:00	8,48	8,64	8,82	9,21	9,55	9,70	9,58	9,39	9,30	9,77	9,24
07:00	10,99	10,68	10,74	11,11	11,48	11,73	11,69	11,43	11,22	11,91	11,30
08:00	11,26	10,65	10,46	11,00	11,31	11,44	11,47	11,27	11,21	11,99	11,21
09:00	10,30	9,73	9,42	10,04	10,17	10,23	10,33	10,16	10,11	10,73	10,12
10:00	9,23	8,77	8,44	8,91	9,09	9,08	9,28	9,19	9,05	9,63	9,07
11:00	9,34	8,83	8,53	9,09	9,25	9,22	9,42	9,42	9,23	9,88	9,22
12:00	9,43	8,78	8,58	9,06	9,29	9,28	9,43	9,50	9,27	9,92	9,25
13:00	9,27	8,61	8,49	8,94	9,13	9,05	9,26	9,36	9,16	9,84	9,11
14:00	9,25	8,68	8,56	9,02	9,15	9,20	9,30	9,46	9,29	9,82	9,17
15:00	9,31	8,74	8,66	9,22	9,31	9,36	9,49	9,56	9,39	10,06	9,31
16:00	8,81	8,50	8,36	8,84	8,91	8,85	8,99	9,13	8,87	9,57	8,88
17:00	8,28	7,88	7,80	8,25	8,30	8,18	8,41	8,46	8,14	8,82	8,25
18:00	7,45	7,24	7,05	7,33	7,53	7,39	7,56	7,65	7,41	8,03	7,46
19:00	6,62	6,66	6,36	6,57	6,91	6,88	6,97	7,09	6,93	7,61	6,86
20:00	6,15	6,20	6,01	6,20	6,48	6,51	6,54	6,59	6,40	7,12	6,42
21:00	5,38	5,49	5,36	5,54	5,77	5,81	5,90	6,02	5,83	6,40	5,75
22:00	4,39	4,69	4,52	4,73	4,95	4,88	4,84	5,13	4,84	5,25	4,82
23:00	4,52	4,85	4,59	4,81	4,95	4,84	4,81	5,03	4,78	5,16	4,83
<i>średnia</i>	8,25	7,98	7,82	8,21	8,42	8,42	8,52	8,55	8,36	8,97	8,35

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Dni tygodnia, dni świąteczne i dni niestandardowe

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.2.3.4) dla dni świątecznych i niestandardowych nie dają poprawy skuteczności dla całego okresu analizy w porównaniu ze skutecznością prognoz uwzględnianych w planach BPKD. Najmniejsza regresja jakości (1,90%) uzyskiwana jest dla czwartków, a największa (10,75%) dla dni świątecznych i niestandardowych.

Tab. 4.2.3.4. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
00:00	3,01	11,00	2,31	1,84	1,90	2,17	9,71	4,01	5,94	9,17	6,52
01:00	2,03	10,46	2,13	1,85	1,99	2,56	9,86	3,69	6,21	9,38	8,28
02:00	1,63	10,25	2,19	2,05	2,13	2,90	10,14	3,65	6,52	9,95	9,15
03:00	1,69	10,33	2,09	2,04	2,21	3,45	10,61	3,67	7,03	10,75	10,53
04:00	2,70	10,07	1,91	1,96	2,27	4,26	10,73	3,78	7,50	11,58	11,68
05:00	6,85	8,90	1,54	1,66	2,12	6,92	11,32	4,21	9,12	13,68	13,98
<i>średnia</i>	2,99	10,17	2,03	1,90	2,10	3,71	10,39	3,84	7,05	10,75	10,02

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

W czwartki najmniejszą regresję prognoz uzyskuje się dla pierwszych dwóch godzin doby (1,84% i 1,85%), a największą dla godziny 02:00 i 03:00 (2,05% i 2,04%). W dni świąteczne i dni niestandardowe najmniejszą regresję prognoz odnotowujemy się dla pierwszych dwóch godzin doby (9,17% i 9,38%), a największą dla godziny 05:00 (13,68%).

Tab. 4.2.3.5. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$
dla metody ważonych współczynników funkcji autokorelacji cząstkowej
w odniesieniu do planów BPKD w latach 2009 – 2018,
w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
06:00	19,41	7,27	2,59	2,74	3,13	14,37	15,17	7,03	14,77	23,14	21,78
07:00	26,10	6,33	3,53	3,57	4,16	17,76	17,60	8,74	17,68	29,11	28,25
08:00	26,60	5,32	3,78	3,86	4,51	15,99	18,37	8,82	17,18	30,28	26,69
09:00	23,98	4,55	3,60	3,69	4,21	13,13	17,66	8,01	15,40	29,23	22,26
10:00	21,26	4,22	3,37	3,48	3,86	11,16	16,11	7,24	13,63	27,81	19,56
11:00	21,51	4,36	3,54	3,64	4,01	11,72	15,75	7,42	13,73	27,77	20,02
12:00	21,66	4,52	3,54	3,69	4,08	12,58	14,69	7,50	13,63	27,23	20,49
13:00	21,54	4,44	3,51	3,49	3,97	13,10	13,69	7,39	13,40	26,50	19,96
14:00	21,67	4,54	3,59	3,59	4,04	14,24	12,53	7,49	13,38	26,31	20,20
15:00	21,88	4,57	3,58	3,62	3,99	14,68	12,83	7,53	13,76	26,82	19,00
16:00	20,39	4,46	3,34	3,44	3,71	14,12	12,69	7,07	13,40	25,25	19,93
17:00	18,78	4,32	3,17	3,27	3,50	13,47	11,24	6,61	12,35	22,90	29,24
18:00	16,95	4,06	2,94	3,10	3,24	12,39	9,55	6,06	10,97	20,82	35,96
19:00	15,88	3,74	2,63	2,87	3,13	12,18	7,56	5,65	9,87	19,02	38,78
20:00	15,41	3,27	2,27	2,48	3,29	11,88	6,32	5,35	9,10	17,13	36,08
21:00	14,39	2,82	2,11	2,06	3,25	11,13	4,46	4,93	7,79	14,38	29,12
22:00	11,96	2,55	2,00	1,88	2,36	9,53	3,48	4,15	6,51	11,48	21,66
23:00	11,41	2,74	2,04	2,09	2,09	9,72	3,73	4,08	6,73	11,11	17,99
średnia	19,49	4,34	3,06	3,14	3,59	12,95	11,86	6,73	12,41	23,13	24,83

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.2.3.5) dla dni świątecznych i niestandardowych nie dają poprawy skuteczności dla całego okresu analizy w porównaniu ze skutecznością prognoz uwzględnianych w planach BPKD. Najmniejszą regresję jakości (3,06%) uzyskuje się dla środy, a największą (24,83%) dla Wigilii Świąt Bożego Narodzenia. W środy najmniejsze błędy prognoz osiągane są dla ostatnich dwóch godzin doby (2,00% i 2,04%), a największe dla godziny 08:00 (3,78%). W Wigilię Świąt Bożego Narodzenia najmniejszy błąd prognoz odnotowywany jest dla godziny 23:00 (17,99%), a największy dla godziny 19:00 (38,78%).

Dni świąteczne i dni niestandardowe

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.2.3.6 i Tab. 4.2.3.7) dla dni świątecznych i niestandardowych w porównaniu ze skutecznością prognoz uwzględnianych w planach BPKD, wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 2,77% dla Sylwestra. Dla Sylwestra najmniejszy stopień regresji jakości prognoz zachodzi dla godziny 01:00 (2,37%).

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.2.3.8 i Tab. 4.2.3.9) dla dni świątecznych i niestandardowych w porównaniu ze skutecznością prognoz uwzględnianych w planach BPKD, wskazuje, że opracowana metoda różni się skutecznością w najkorzystniejszym przypadku o 6,22% dla Święta Trzech Króli. Dla Święta Trzech Króli najmniejsza różnica uzyskanej jakości zachodzi dla godziny 23:00 (3,49%).

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.2.3.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
00:00	2,06	3,42	19,19	10,14	6,86	13,81	5,92	10,02
01:00	2,19	3,30	19,04	9,79	6,94	13,14	6,24	10,21
02:00	4,02	3,48	19,73	7,91	8,16	12,53	5,33	10,71
03:00	6,35	3,54	21,19	6,32	8,54	12,42	5,13	11,41
04:00	9,19	3,52	20,89	5,85	10,45	13,09	4,53	13,49
05:00	11,29	4,03	17,53	5,58	15,12	13,93	3,44	15,20
średnia	5,85	3,55	19,59	7,60	9,34	13,15	5,10	11,84

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.2.3.7. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
00:00	1,26	2,23	8,71	7,25	6,52	18,45	19,32	2,89
01:00	2,78	2,38	9,24	8,91	8,28	19,19	17,67	2,37
02:00	4,74	3,16	9,56	9,59	9,15	21,14	17,57	3,04
03:00	6,11	4,68	10,66	10,83	10,53	23,31	17,35	2,77
04:00	7,91	5,93	12,43	11,60	11,68	25,21	15,92	2,62
05:00	14,65	11,06	16,80	14,83	13,98	28,32	16,38	2,91
średnia	6,24	4,91	11,23	10,50	10,02	22,60	17,37	2,77

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.2.3.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
06:00	16,78	6,99	24,02	6,11	27,70	18,88	10,52	19,87
07:00	23,65	8,66	26,07	4,84	33,49	21,10	15,51	22,02
08:00	30,52	8,65	27,70	5,87	30,92	19,72	15,75	23,11
09:00	32,66	7,84	32,40	8,83	26,78	16,95	14,05	22,32
10:00	30,58	6,96	36,87	10,56	23,52	14,55	12,33	21,35
11:00	26,21	6,86	38,49	9,33	24,06	15,56	11,87	21,05
12:00	21,64	6,77	37,66	9,52	24,49	15,27	11,85	20,44
13:00	18,98	6,68	37,04	11,54	23,74	14,36	11,81	19,79
14:00	16,76	6,74	34,45	13,13	24,51	13,71	11,98	18,56
15:00	16,20	7,00	34,79	14,02	25,85	14,19	12,98	18,88
16:00	13,56	6,57	34,94	14,56	26,25	13,71	12,24	19,52
17:00	7,56	5,89	33,82	13,39	25,09	12,87	10,63	18,41
18:00	4,18	5,36	32,77	11,79	23,34	11,32	8,45	16,29
19:00	3,04	5,02	28,10	10,48	22,48	10,65	7,36	13,58
20:00	2,51	4,64	23,45	7,88	21,12	10,70	7,76	10,77
21:00	2,86	4,25	17,97	6,63	17,05	8,98	6,92	7,07
22:00	3,45	3,50	14,90	5,63	13,59	8,08	4,20	5,30
23:00	5,20	3,49	11,92	4,65	14,03	6,91	3,71	5,60
średnia	15,35	6,22	29,30	9,38	23,78	13,75	10,55	16,89

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.2.3.9. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
06:00	33,16	22,80	31,47	27,06	21,78	40,12	24,12	7,20
07:00	42,16	27,98	37,95	35,82	28,25	51,44	32,28	11,78
08:00	40,65	28,51	37,90	35,09	26,69	54,93	36,96	13,67
09:00	37,29	26,69	37,81	30,51	22,26	52,42	35,04	12,36
10:00	35,12	24,86	39,04	25,89	19,56	48,66	31,66	10,31
11:00	37,13	26,10	42,48	24,70	20,02	48,70	29,64	10,67
12:00	36,86	26,93	43,77	24,30	20,49	47,76	28,57	10,58
13:00	35,09	26,58	42,10	23,19	19,96	47,31	27,80	10,28
14:00	35,61	26,78	41,95	23,02	20,20	47,58	27,74	9,88
15:00	37,84	27,26	40,80	23,19	19,00	48,23	28,77	9,28
16:00	37,85	27,28	32,34	21,17	19,93	45,90	24,45	7,63
17:00	35,90	25,41	28,97	20,75	29,24	44,60	16,61	6,68
18:00	32,33	23,29	30,43	19,87	35,96	42,34	10,57	6,87
19:00	31,50	20,35	29,14	19,73	38,78	39,56	8,10	10,47
20:00	29,99	17,79	27,16	18,38	36,08	36,12	7,60	15,58
21:00	24,68	15,90	23,18	16,00	29,12	31,19	6,54	15,23
22:00	18,64	12,56	19,82	12,15	21,66	25,06	5,58	10,91
23:00	18,49	11,87	19,64	11,86	17,99	22,31	7,28	6,53
średnia	33,35	23,28	33,66	22,93	24,83	43,01	21,63	10,33

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.2.3.10) dla dni świątecznych i niestandardowych w porównaniu ze skutecznością prognoz uwzględnianych w planach BPKD, wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 2,77% dla Sylwestra. W Sylwestra otrzymywana jest poprawa jakości prognozowania dla 2014 roku (0,84%) i dla 2018 roku (1,15%).

Tab. 4.2.3.10. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	5,69	11,62	9,53	1,69	3,25	6,28	6,82	2,62	9,24	1,75	5,85
S02	n.d.	n.d.	6,60	2,46	3,84	4,54	5,27	5,95	3,36	3,47	3,55
S03	21,47	17,07	24,52	21,95	18,13	24,59	21,55	20,12	24,79	1,75	19,59
S04	10,68	14,17	10,83	7,81	6,82	9,69	7,38	2,44	4,32	1,84	7,60
S05	10,93	10,61	11,07	2,53	6,90	15,31	7,56	17,44	7,70	3,39	9,34
S06	24,80	16,44	1,70	15,69	13,29	15,44	18,58	2,89	5,17	17,53	13,15
S07	10,05	4,39	2,99	4,32	5,85	5,78	9,30	2,51	3,95	1,88	5,10
S08	3,36	12,71	12,01	12,28	12,15	13,27	11,14	11,01	11,98	18,49	11,84
S09	6,54	7,70	4,64	7,15	6,81	6,68	5,92	7,59	5,57	3,80	6,24
S10	3,18	8,59	6,27	2,49	5,78	4,48	9,99	3,71	1,84	2,74	4,91
S11	16,97	9,84	3,18	12,64	10,43	15,53	20,43	3,14	9,02	11,15	11,23
S12	5,40	10,58	8,18	14,95	7,47	5,16	9,33	11,91	13,20	18,84	10,50
S13	8,48	13,51	16,14	1,74	4,04	11,83	8,67	15,85	19,37	0,60	10,02
S14	24,01	24,91	22,29	16,70	27,66	25,66	28,14	26,64	12,15	17,86	22,60
S15	25,85	14,32	7,35	25,18	20,60	17,62	22,25	6,57	13,00	20,94	17,37
S16	4,06	3,14	2,65	2,65	4,86	-0,84	0,20	5,24	6,85	-1,15	2,77
średnia	11,34	11,23	9,37	9,51	9,87	11,31	12,03	9,10	9,47	7,80	10,10

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, n.d. - nie dotyczy.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.2.3.11) dla dni świątecznych i niestandardowych w porównaniu ze skutecznością prognoz uwzględnianych w planach BPKD, wskazuje, że opracowana metoda różni się efektywnością w najkorzystniejszym przypadku o (6,22%) dla Święta Trzech Króli.

Tab. 4.2.3.11. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	14,71	17,97	21,96	11,33	19,18	19,82	18,12	14,78	12,02	3,61	15,35
S02	n.d.	n.d.	8,12	7,23	7,38	7,48	6,72	9,67	8,93	6,62	6,22
S03	31,01	36,27	34,32	29,04	31,13	36,09	30,97	33,31	27,23	3,61	29,30
S04	9,99	8,48	11,59	9,48	8,80	10,83	6,15	9,59	5,01	13,83	9,38
S05	32,74	26,34	12,51	27,19	26,88	32,73	27,76	19,58	1,19	30,86	23,78
S06	24,74	16,73	13,76	9,20	12,00	16,46	23,06	7,46	4,03	10,07	13,75
S07	2,15	2,74	3,35	15,28	9,32	11,30	3,74	27,98	20,88	8,79	10,55
S08	16,00	15,40	15,24	14,56	24,89	14,62	16,09	18,59	13,42	20,05	16,89
S09	35,61	35,94	33,61	33,17	32,31	32,56	35,45	35,31	29,89	29,63	33,35
S10	30,52	14,88	5,54	25,53	30,67	33,20	29,05	4,09	27,85	31,43	23,28
S11	22,02	11,89	37,31	39,93	42,68	41,19	27,41	38,44	37,93	37,84	33,66
S12	26,20	24,19	26,46	19,98	2,68	27,12	28,43	25,16	25,99	23,06	22,93
S13	26,27	29,18	28,65	8,32	28,98	29,80	31,03	33,85	22,50	9,73	24,83
S14	51,34	43,35	30,17	52,00	49,03	49,83	51,97	30,33	19,84	52,27	43,01
S15	28,85	10,02	6,92	31,43	24,20	22,25	23,30	5,42	40,14	23,76	21,63
S16	10,95	11,49	14,58	4,62	7,39	10,28	9,43	17,61	11,38	5,56	10,33
<i>średnia</i>	<i>22,69</i>	<i>19,05</i>	<i>19,00</i>	<i>21,14</i>	<i>22,34</i>	<i>24,72</i>	<i>23,04</i>	<i>20,70</i>	<i>19,26</i>	<i>19,42</i>	<i>21,14</i>

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, n.d. – nie dotyczy.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.2.4. Hybrydowa integracja podejścia PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej

Metody hybrydowe, łączące ze sobą podejścia bazujące na co najmniej dwóch różnych metodach prognoz coraz częściej stosowane są przez badaczy. Połączenie właściwości modeli wchodzących w skład modelu hybrydowego charakteryzuje się często większą efektywnością prognoz niż każdego z modeli z osobna, co wynika z różnych właściwości każdej z metod. Dla analizowanego okresu od 2009 do 2018 roku wyodrębniono dla każdej godziny doby większą jakość prognozy pomiędzy skutecznością osiąganą przez PSE S.A. i skutecznością osiągniętą z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej. Wyniki wskazujące na zwiększoną poprawę, dzięki hybrydowej integracji metod, w zestawieniach tabelarycznych poniżej (Tab. 4.2.4.1, Tab. 4.2.4.2, Tab. 4.2.4.3, Tab. 4.2.4.4, Tab. 4.2.4.5) zaznaczono kolorem jasnozielonym. Wyniki hybrydowej integracji wyników obu metod wskazują (Tab. 4.2.4.1), że możliwe jest osiągnięcie jakości prognozowania większej o 0,08% niż w przypadku metod wykorzystywanych przez PSE S.A. Największa poprawa jakości odnotowywana jest dla 2009 roku (0,21%), natomiast w pozostałych latach analizy wzrost efektywności kształtuje się na poziomie od 0,06% do 0,08%, wskazując na stabilność zastosowanego podejścia. Dla pierwszych pięciu godzin doby odnotowywana poprawa skuteczności kształtuje się na poziomie 0,15%, natomiast dla

pozostałych godzin doby odnotowuje się poprawę na poziomie 0,06%. Największa poprawa jakości dla pierwszych pięciu godzin doby obserwowana jest dla 2009 roku (0,61%), natomiast w pozostałych latach analizy poprawa jakości kształtuje się na poziomie od 0,09% do 0,11% wskazując ponownie na stabilność zaproponowanej metody. W przypadku pozostałych osiemnastu godzin doby nie obserwuje się zwiększonej poprawy efektywności dla 2009 roku, natomiast zauważalna jest stabilność w całym analizowanym okresie w przedziale od 0,05% do 0,08%. Analogiczna analiza w podziale na typy dni wskazuje, dla całego okresu analizy, że największą poprawą efektywności w wyniku zastosowania hybrydowej integracji wyników uzyskuje się dla czwartków (od 0,18% do 0,31%), natomiast w odniesieniu do wszystkich wyodrębnionych typów dni otrzymywana jest stabilność zastosowanego podejścia. Również w przypadku pierwszych pięciu godzin doby odnotowuje się większą skuteczność dzięki zastosowaniu wskazanego podejścia (przedział od 0,02% do 0,31%) z największym przyrostem skuteczności dla czwartków (0,31%). Dla pozostałych osiemnastu godzin nie zaobserwowano poprawy efektywności wyłącznie dla poniedziałków. W przypadku pozostałych typów dni w tym przedziale doby zauważalna jest poprawa jakości w przedziale od 0,01%, dla sobót, do 0,13% dla śród i czwartków.

Hybrydowa integracja wyników PSE S.A. i opracowanej metody ważonych współczynników funkcji autokorelacji cząstkowej, dla całego okresu analizy od 2009 roku do 2018 roku, umożliwia obniżenie błędów MAPE prognoz dla całej doby z poziomu 0,82% do 0,74%, dla pierwszych sześciu godzin doby z poziomu 1,02% do poziomu 0,87% oraz dla pozostałych osiemnastu godzin doby z poziomu 0,75% do poziomu 0,69%.

Tab. 4.2.4.1. Skuteczność roczna prognoz oraz w podziale na typy dni i godziny doby dla hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej, wyrażona wartościami błędów MAPE, [%].

Rok	Cała doba	00:00	06:00	Dzień	Cała doba	00:00	06:00
		– 05:00	– 23:00			– 05:00	– 23:00
2009	0,21	0,61	0,07	Poniedziałek	0,04	0,18	0,00
2010	0,08	0,10	0,08	Wtorek	0,05	0,02	0,06
2011	0,07	0,09	0,06	Środa	0,15	0,23	0,13
2012	0,06	0,09	0,05	Czwartek	0,18	0,31	0,13
2013	0,06	0,09	0,06	Piątek	0,13	0,22	0,10
2014	0,07	0,11	0,06	Sobota	0,03	0,09	0,01
2015	0,08	0,11	0,07	Niedziela	0,02	0,03	0,02
2016	0,07	0,09	0,06	Dni robocze	0,11	0,19	0,08
2017	0,07	0,10	0,05	Dni wolne od pracy	0,02	0,06	0,01
2018	0,06	0,09	0,05	Dni świąteczne	0,02	0,04	0,01
<i>średnia</i>	<i>0,08</i>	<i>0,15</i>	<i>0,06</i>	<i>średnia</i>	–	–	–

Legenda: kolor zielony: skuteczność poprawiona dzięki hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Liczba prognoz o większej skuteczności z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej, w porównaniu do skuteczności osiągniętej przez PSE S.A., odniesiona do liczby wszystkich prognoz dla każdej godziny z osobna w podziale na wyodrębnione typy dni, wyrażona wartościami procentowymi (Tab. 4.2.4.2), wskazuje, że zaproponowana metoda w połączeniu z podejściem

stosowanym przez PSE S.A. jest skuteczna dla wszystkich typów dni z wyjątkiem godziny czwartej dla pierwszych sześciu godzin doby. Taka sama analiza dla pozostałych osiemnastu godzin doby (Tab. 4.2.4.3) wskazuje, że zastosowanie hybrydowej integracji wyników nie daje pozytywnego skutku tylko dla poniedziałków (20 spośród 24 godzin) oraz dla niedziel w przypadku dwóch godzin porannych i dla dni świątecznych dla czterech godzin popołudniowych.

Tab. 4.2.4.2. Liczba prognoz w poszczególnych latach 2009 – 2018 oraz w podziale na typy dni i godziny doby w godzinach 00:00 – 05:00 doby, w których metoda ważonych współczynników funkcji autokorelacji cząstkowej cechuje się skutecznością większą niż osiąganą przez PSE S.A. wyrażona wartościami procentowymi, [%].

<i>h</i>	2009 – 2018	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	Dni robocze	Dni wolne od pracy	Dni świąteczne
00:00	17,20	14,46	0,59	18,50	29,72	30,37	27,31	1,65	18,71	14,18	7,75
01:00	18,18	28,11	1,38	23,43	31,73	25,84	17,88	1,23	22,04	9,58	9,30
02:00	16,07	27,31	1,38	20,67	27,11	24,46	13,75	1,03	20,14	7,38	3,88
03:00	15,12	26,71	1,18	21,85	25,70	22,88	9,43	1,65	19,62	5,36	1,55
04:00	13,91	13,05	1,18	25,98	29,92	22,88	5,89	2,06	18,59	3,83	0,00
05:00	18,35	3,01	1,38	42,52	44,98	35,90	2,55	1,85	25,58	2,30	3,10
średnia	16,47	18,78	1,18	25,49	31,53	27,05	12,80	1,58	20,78	7,10	4,26

Legenda: kolor zielony: skuteczność poprawiona dzięki hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.2.4.3. Liczba prognoz w poszczególnych latach 2009 – 2018 oraz w podziale na typy dni i godziny doby w godzinach 06:00 – 23:00 doby, w których metoda ważonych współczynników funkcji autokorelacji cząstkowej cechuje się skutecznością większą niż osiąganą przez PSE S.A. wyrażona wartościami procentowymi, [%].

<i>h</i>	2009 – 2018	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	Dni robocze	Dni wolne od pracy	Dni świąteczne
06:00	15,50	0,00	2,76	34,25	39,56	32,94	1,77	0,62	21,92	1,15	1,55
07:00	11,58	0,00	6,90	21,65	31,93	20,71	1,77	0,62	16,24	1,15	1,55
08:00	8,98	0,00	8,28	20,08	21,89	12,43	1,96	0,00	12,55	1,05	1,55
09:00	9,17	0,00	12,43	20,28	19,28	13,02	1,18	0,00	13,03	0,57	0,78
10:00	10,41	0,00	14,99	21,85	20,68	16,96	0,39	0,21	14,93	0,29	0,78
11:00	8,05	0,00	11,05	16,54	17,67	11,64	0,79	0,41	11,40	0,57	0,78
12:00	7,69	0,00	8,09	19,49	15,26	11,24	0,79	0,41	10,84	0,57	0,78
13:00	8,65	0,00	6,90	19,29	19,88	13,81	1,96	0,41	11,99	1,15	0,78
14:00	7,97	0,00	6,71	19,09	18,07	11,05	1,38	1,23	11,00	1,25	0,00
15:00	7,91	0,00	8,28	19,29	16,67	11,64	0,98	0,21	11,20	0,57	0,00
16:00	7,97	0,00	7,89	15,75	18,67	13,81	0,79	0,82	11,24	0,77	0,00
17:00	8,49	0,20	7,10	16,93	19,88	15,58	0,79	1,03	11,95	0,86	0,00
18:00	9,26	0,00	6,51	20,47	18,07	19,13	1,38	0,82	12,87	1,25	2,33
19:00	10,73	0,20	8,48	26,38	22,49	16,57	0,98	1,85	14,85	1,53	3,10
20:00	13,01	0,00	12,82	34,45	30,12	11,83	0,98	2,88	17,87	2,01	4,65
21:00	14,65	0,00	15,19	33,07	37,15	12,62	0,79	7,41	19,62	3,83	0,78
22:00	16,54	0,20	17,16	30,91	31,53	25,25	1,38	12,76	21,05	6,61	3,88
23:00	14,40	0,20	13,81	25,98	23,29	29,98	1,18	9,26	18,71	4,98	3,10
średnia	10,61	0,04	9,74	23,10	23,45	16,68	1,18	2,27	14,63	1,68	1,46

Legenda: kolor zielony: skuteczność poprawiona dzięki hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Dla pierwszych sześciu godzin doby (Tab. 4.2.4.2), w analizowanym aspekcie, największą liczbą prognoz dających skuteczność większą niż przy podejściu wykorzystujących wyłącznie metodykę PSE S.A. charakteryzują się czwartki (31,53%), natomiast w całym okresie analizy otrzymywanych jest 16,47% prognoz

skuteczniejszych z wykorzystaniem opracowanej metody ważonych współczynników funkcji autokorelacji cząstkowej. W odniesieniu do pozostałych osiemnastu godzin doby (Tab. 4.2.4.3) opracowana metoda ważonych współczynników funkcji autokorelacji cząstkowej daje prognozy skuteczniejsze w całym okresie analizy w 10,61% wszystkich opracowanych prognoz dla każdej godziny doby z osobna, natomiast w przypadku czwartków odnotowuje się poprawę efektywności prognozowania na poziomie 23,45%.

Wysoka stabilność hybrydowej integracji wyników uzyskiwana jest dla wszystkich godzin doby (Tab. 4.2.4.4 i Tab. 4.2.4.5) w całym dziesięcioletnim okresie analizy co potwierdza, że stosowanie zalet obu sposobów prognozowania (hybrydowa integracja wyników) daje większą jakość niż wyłącznie z zastosowaniem podejścia do prognozowania stosowanego w PSE S.A., co stanowi jeden z kluczowych elementów składających się na potwierdzenie trzeciej hipotezy postawionej w rozprawie.

Tab. 4.2.4.4. Skuteczność prognoz w poszczególnych latach 2009 – 2018 w godzinach 00:00 – 05:00 doby dla hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej wyrażona wartościami błędów MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009-2018
00:00	0,36	0,12	0,11	0,08	0,09	0,14	0,12	0,12	0,10	0,11	0,13
01:00	0,64	0,09	0,10	0,11	0,11	0,09	0,14	0,11	0,10	0,08	0,16
02:00	0,76	0,07	0,07	0,07	0,07	0,09	0,08	0,06	0,10	0,07	0,14
03:00	0,85	0,08	0,06	0,08	0,08	0,09	0,07	0,06	0,07	0,04	0,15
04:00	0,72	0,09	0,06	0,06	0,05	0,08	0,06	0,06	0,06	0,07	0,13
05:00	0,35	0,14	0,16	0,12	0,14	0,17	0,18	0,14	0,17	0,17	0,17
<i>średnia</i>	0,61	0,10	0,09	0,09	0,09	0,11	0,11	0,09	0,10	0,09	0,15

Legenda: kolor zielony: skuteczność poprawiona dzięki hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.2.4.5. Skuteczność prognoz w poszczególnych latach 2009 – 2018 w godzinach 06:00 – 23:00 doby dla hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej wyrażona wartościami błędów MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
06:00	0,08	0,15	0,15	0,11	0,10	0,10	0,13	0,12	0,15	0,17	0,13
07:00	0,08	0,12	0,08	0,09	0,09	0,06	0,07	0,06	0,07	0,06	0,08
08:00	0,07	0,06	0,05	0,05	0,05	0,06	0,05	0,03	0,04	0,04	0,05
09:00	0,04	0,04	0,05	0,03	0,03	0,05	0,06	0,05	0,03	0,03	0,04
10:00	0,05	0,07	0,05	0,05	0,04	0,04	0,06	0,05	0,03	0,04	0,05
11:00	0,05	0,05	0,03	0,03	0,03	0,03	0,04	0,03	0,02	0,03	0,03
12:00	0,03	0,03	0,02	0,03	0,04	0,03	0,04	0,02	0,04	0,03	0,03
13:00	0,06	0,04	0,04	0,03	0,03	0,03	0,05	0,04	0,04	0,03	0,04
14:00	0,04	0,03	0,04	0,03	0,02	0,03	0,04	0,03	0,04	0,02	0,03
15:00	0,04	0,05	0,03	0,02	0,03	0,03	0,03	0,03	0,04	0,03	0,03
16:00	0,04	0,05	0,05	0,03	0,05	0,03	0,03	0,03	0,04	0,02	0,04
17:00	0,06	0,05	0,04	0,03	0,04	0,04	0,02	0,04	0,04	0,03	0,04
18:00	0,04	0,06	0,06	0,05	0,05	0,05	0,04	0,05	0,05	0,03	0,05
19:00	0,09	0,08	0,07	0,06	0,06	0,06	0,06	0,04	0,04	0,04	0,06
20:00	0,11	0,12	0,08	0,06	0,07	0,09	0,10	0,07	0,06	0,07	0,08
21:00	0,14	0,12	0,10	0,10	0,09	0,12	0,12	0,10	0,08	0,07	0,10
22:00	0,16	0,16	0,12	0,10	0,10	0,12	0,13	0,14	0,09	0,08	0,12
23:00	0,15	0,09	0,11	0,08	0,07	0,09	0,11	0,10	0,07	0,07	0,09
<i>średnia</i>	0,07	0,08	0,06	0,05	0,06	0,06	0,07	0,06	0,05	0,05	0,06

Legenda: kolor zielony: skuteczność poprawiona dzięki hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.3. Walidacja modelu ważonych współczynników funkcji autokorelacji cząstkowej – studium przypadku wybranych zagranicznych systemów elektroenergetycznych

Testowanie metod i modeli statystycznych przeprowadzane jest na podstawie danych innych niż wykorzystane w procesie ich budowy. W tym celu zgromadzono dane o godzinowym kształtowaniu zapotrzebowania na moc elektryczną w SEE europejskich krajów zrzeszonych w ENTSO – E. Systemy różnych krajów obciążane są w sposób podobny do KSE, jednakże ich dobowe przebiegi obciążeń mogą charakteryzować się innymi cechami, których nie posiadają przebiegi zapotrzebowania na moc elektryczną w KSE. Przebiegi innych systemów mogą charakteryzować się odmiennymi tempami narastania i opadania krzywych zapotrzebowania na moc elektryczną oraz innymi godzinami występowania najmniejszego i największego zapotrzebowania na moc elektryczną. W konsekwencji przyjęto, że przeprowadzenie testów na profilach obciążeń innych systemów elektroenergetycznych będzie stanowić wartościowe źródło wiedzy o efektywności zaproponowanej metody. W tym celu zgromadzono dane historyczne o zapotrzebowaniu na moc zagranicznych systemów elektroenergetycznych, przedstawionych w Tabeli 4.3.1. Założono, że w badaniach uwzględnione zostaną dwa kraje (jeden z grupy krajów nordyckich i jeden z zachodnioeuropejski), które charakteryzują się zaawansowanymi rozwiązaniami na rynkach energii elektrycznej oraz zamożnością i zróżnicowaniem odbiorców.

Tab. 4.3.1. Systemy elektroenergetyczne krajów wyznaczone do walidacji.

Kraj	Operator Systemu Przesyłowego	Witryna internetowa
Szwecja	Svenska Kraftnät	www.svk.se [378]
Francja	Rte	www.rte-france.com [377]

Źródło: Witryna internetowa www.entsoe.eu [376].

W Tabeli 4.3.2 zamieszczono wykaz dni świątecznych będących dniami wolnymi od pracy dla poszczególnych zagranicznych systemów elektroenergetycznych.

Tab. 4.3.2. Wykaz dni świątecznych wolnych od pracy na tle dni świątecznych i niestandardowych w Polsce wytypowanych do analiz walidacyjnych.

Św.	Szwecja	Francja	Św.	Szwecja	Francja
S01	Tak	Tak	S09	n.d.	n.d.
S02	Tak	n.d.	S10	n.d.	Tak
S03	Tak	n.d.	S11	n.d.	Tak
S04	Tak	Tak	S12	n.d.	Tak
S05	Tak	Tak	S13	n.d.	Tak
S06	n.d.	n.d.	S14	Tak	Tak
S07	n.d.	n.d.	S15	Tak	n.d.
S08	Tak	Tak	S16	n.d.	n.d.

Legenda: Tak (wraz z kolorem zielonym): Święto będące dniem wolnym od pracy pokrywające się z kalendarzem obowiązującym dla Polski; n.d.: nie dotyczy.

Źródło: Opracowanie własne na podstawie kalendarzy dni świątecznych analizowanych krajów.

4.3.1. Skuteczność prognozowania dla zagranicznych systemów elektroenergetycznych

Najmniejsze wartości błędów MAPE zwalidowane dla wszystkich godzin okresu sześciu lat wskazują, że dla systemu szwedzkiego jak i dla systemu francuskiego osiągnęto idealne

wykonania prognozy. W Tabeli 4.3.1.1 przedstawiono wyniki z dokładnością do tysięcznej części procentowej wartości błędów MAPE w celu zwalidowania wyników.

Tab. 4.3.1.1. Skuteczność prognozowania w latach kalendarzowych w horyzoncie $n+1$ dla zagranicznych SEE latach 2013 – 2018, wyrażona minimalnymi wartościami błędu MAPE, [%].

Rok/lata	Szwecja	Francja
2013	0,000	0,000
2014	0,000	0,000
2015	0,000	0,000
2016	0,000	0,000
2017	0,000	0,003
2018	0,000	0,000
2013 – 2018	0,000	0,000

Źródło: Opracowanie własne na podstawie witryn internetowych zagranicznych OSP [378], [377].

Minimalne wartości błędów MAPE (Tab. 4.3.1.2) za cały okres analizy zarówno dla systemu szwedzkiego (2,52%) jak i francuskiego (2,50%) kształtują się na tym samym poziomie. Dla systemu szwedzkiego najmniejsza wartość błędu MAPE (2,34%), w grupie wartości minimalnych, odnotowywana jest dla 2017 roku, natomiast dla systemu francuskiego (2,40%) dla 2014 roku.

Tab. 4.3.1.2. Skuteczność prognozowania w latach kalendarzowych w horyzoncie $n+1$ dla zagranicznych SEE w okresie 2013 – 2018, wyrażona wartościami błędu MAPE, [%].

Rok/lata	Szwecja	Francja
2013	2,84	2,61
2014	2,42	2,40
2015	2,39	2,52
2016	2,54	2,57
2017	2,34	2,48
2018	2,60	2,42
2013 – 2018	2,52	2,50

Źródło: Opracowanie własne na podstawie witryn internetowych zagranicznych OSP [378], [377].

Maksymalne wartości błędów MAPE (Tab. 4.3.1.3) za cały okres analizy zarówno dla systemu szwedzkiego (19,79%) jak i francuskiego (51,27%) kształtują się na znacząco różnych poziomach (z korzyścią dla systemu szwedzkiego).

Tab. 4.3.1.3. Skuteczność prognozowania w latach kalendarzowych w horyzoncie $n+1$ dla zagranicznych SEE latach 2013 – 2018 wyrażona maksymalnymi wartościami błędu MAPE, [%].

Rok/lata	Szwecja	Francja
2013	13,76	17,13
2014	16,42	13,84
2015	14,92	49,97
2016	15,77	51,27
2017	13,15	47,98
2018	19,79	12,58
2013 – 2018	19,79	51,27

Źródło: Opracowanie własne na podstawie witryn internetowych zagranicznych OSP [378], [377].

Odnotowywana wartość różnicy skuteczności pomiędzy oboma zagranicznymi systemami wynosi 31,48%. Dla systemu szwedzkiego najmniejsza wartość błędu MAPE (13,15%), w grupie wartości maksymalnych, odnotowywana jest dla 2017 roku, natomiast dla systemu francuskiego (12,58%) dla 2018 roku.

4.3.2. System szwedzki

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej testowanej na danych historycznych systemu Szwecji dla godzin 00:00 – 05:00 (Tab. 4.3.2.1) wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 2,58% dla godziny 00:00.

Tab. 4.3.2.1. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2013	2014	2015	2016	2017	2018	2009 – 2018
00:00	2,16	3,07	2,77	2,38	2,52	2,61	2,58
01:00	2,34	2,95	2,88	2,78	2,81	3,12	2,84
02:00	2,47	2,83	2,88	2,99	2,84	3,17	2,91
03:00	2,59	3,02	3,03	3,30	3,15	3,34	3,07
04:00	2,81	3,17	3,11	3,47	3,49	3,71	3,25
05:00	4,12	4,10	4,19	4,64	4,67	4,84	4,31
<i>średnia</i>	2,75	3,19	3,14	3,26	3,25	3,47	3,16

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej szwedzkiego OSP [378].

Tab. 4.3.2.2. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2013	2014	2015	2016	2017	2018	2009 – 2018
06:00	7,88	7,96	8,09	8,35	8,24	7,73	7,80
07:00	9,93	9,94	10,12	10,11	10,09	9,76	9,78
08:00	9,71	9,66	9,67	8,46	8,75	10,16	9,20
09:00	8,46	8,45	8,63	7,76	7,95	8,99	8,22
10:00	7,28	7,52	7,88	7,48	7,38	8,16	7,48
11:00	7,06	7,64	8,06	8,10	7,87	8,24	7,67
12:00	6,91	7,64	8,08	8,07	7,94	8,02	7,60
13:00	6,70	7,52	7,81	7,65	7,67	7,92	7,38
14:00	6,67	7,62	7,76	7,62	7,69	7,84	7,37
15:00	7,03	7,75	8,08	7,78	7,80	8,10	7,56
16:00	6,75	7,34	7,50	7,31	7,33	7,66	7,16
17:00	6,38	6,57	6,82	6,87	6,77	6,89	6,61
18:00	5,57	5,80	5,96	5,99	6,00	6,22	5,82
19:00	5,15	5,35	5,47	5,57	5,49	5,73	5,32
20:00	4,72	4,87	5,23	5,17	4,96	5,28	4,89
21:00	3,56	4,12	4,39	4,22	4,05	4,29	3,95
22:00	2,38	3,08	3,01	2,95	2,97	3,01	2,80
23:00	1,80	2,86	2,69	2,29	2,57	2,46	2,41
<i>średnia</i>	6,33	6,76	6,96	6,76	6,75	7,03	6,61

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej szwedzkiego OSP [378].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej testowanej na danych historycznych systemu Szwecji dla godzin 06:00 – 23:00 (Tab. 4.3.2.2) wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 2,41% dla godziny 23:00.

Dni tygodnia, dni świąteczne i dni niestandardowe

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.3.2.3) w podziale na typy dni daje poprawę skuteczności

w porównaniu do prognoz szwedzkiego OSP. Poprawę skuteczności, na poziomie 1,55%, uzyskuje się dla niedziel. Największa regresja jakości, na poziomie 9,17%, odnotowywana się dla dni świątecznych.

Tab. 4.3.2.3. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
00:00	1,00	8,84	0,47	0,16	-0,13	0,10	-2,42	2,07	3,87	7,44	4,39
01:00	0,39	8,87	0,75	0,54	0,39	0,76	-1,79	2,19	4,46	7,91	5,89
02:00	0,07	8,71	0,77	0,70	0,52	1,11	-1,50	2,15	4,81	8,35	7,00
03:00	0,13	8,82	0,74	0,57	0,69	1,61	-1,48	2,19	5,29	9,13	8,59
04:00	1,12	8,46	0,54	0,42	0,67	2,37	-1,27	2,24	5,77	9,92	9,28
05:00	5,81	7,45	0,31	0,62	0,99	5,10	-0,83	3,03	7,50	12,27	11,59
średnia	1,42	8,52	0,60	0,50	0,52	1,84	-1,55	2,31	5,28	9,17	7,79

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej szwedzkiego OSP [378].

Tab. 4.3.2.4. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
06:00	17,67	5,55	1,03	1,33	2,11	12,95	0,08	5,54	13,46	21,74	18,79
07:00	24,27	4,58	1,74	1,94	2,93	16,57	0,52	7,09	16,49	27,80	25,28
08:00	24,34	3,28	1,57	1,62	2,41	14,13	0,52	6,65	15,56	28,73	22,86
09:00	21,90	2,68	1,74	1,77	2,14	11,25	0,45	6,05	13,65	27,57	18,79
10:00	19,46	2,73	1,75	1,97	2,16	9,57	0,56	5,62	12,13	26,25	16,31
11:00	19,82	2,83	2,08	2,19	2,44	10,10	0,58	5,88	12,14	26,22	17,45
12:00	19,88	2,86	2,15	2,11	2,36	10,82	0,54	5,87	11,92	25,46	17,64
13:00	19,71	2,61	2,01	1,94	2,08	11,27	0,50	5,67	11,65	24,69	17,41
14:00	19,86	2,69	1,88	1,91	2,04	12,27	0,52	5,68	11,58	24,16	17,41
15:00	20,07	2,89	1,91	2,00	2,13	12,74	0,58	5,80	11,96	24,75	15,84
16:00	18,62	2,71	1,66	1,79	1,90	12,33	0,72	5,34	11,72	23,30	17,10
17:00	17,10	2,67	1,52	1,73	1,79	11,77	0,63	4,96	10,71	21,17	26,31
18:00	15,37	2,29	1,26	1,56	1,50	10,74	0,65	4,40	9,38	19,02	33,75
19:00	14,30	2,12	1,18	1,50	1,49	10,64	0,45	4,12	8,31	17,48	36,52
20:00	13,94	1,83	0,86	1,13	1,45	10,25	0,09	3,84	7,50	15,59	33,81
21:00	12,47	1,12	0,45	0,58	1,17	9,27	-0,52	3,16	5,94	12,57	26,70
22:00	9,59	0,49	-0,05	0,08	0,34	7,62	-0,81	2,09	4,58	9,26	19,03
23:00	8,71	0,19	-0,31	-0,24	-0,29	7,43	-1,02	1,61	4,40	8,64	15,36
średnia	17,61	2,56	1,36	1,49	1,78	11,21	0,28	4,97	10,73	21,36	22,02

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej szwedzkiego OSP [378].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06 – 00:00 (Tab. 4.3.2.4) w podziale na typy dni wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 0,28% dla niedziel.

Dni świąteczne i dni niestandardowe

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.3.2.5) dla dni świątecznych i niestandardowych wskazują,

że opracowana metoda różni się skutecznością w najkorzystniejszym przypadku o 2,50% dla Święta 3 Króli.

Tab. 4.3.2.5. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędów MAPE, [%].

Św.	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	3,45	6,17	3,24	-1,96	4,66	1,41	2,57
S02	-0,35	0,39	4,18	5,42	3,48	2,39	2,50
S03	17,77	21,21	22,17	21,42	24,67	1,92	16,02
S04	7,13	7,76	7,21	2,43	4,83	0,92	4,90
S05	6,12	13,95	7,79	13,68	3,64	3,26	7,63
S06	12,80	15,71	13,27	0,18	-3,03	17,51	8,92
S07	5,04	4,36	7,86	0,25	0,16	-0,04	3,52
S08	6,40	6,45	7,82	11,67	8,35	9,45	8,31
S09	4,99	5,33	4,44	3,80	2,07	4,23	4,84
S10	3,53	4,71	9,82	2,85	0,59	1,86	4,77
S11	9,91	11,53	17,95	1,09	4,77	11,73	9,71
S12	4,59	4,66	8,46	11,86	10,95	15,30	9,69
S13	0,04	8,39	7,11	13,71	18,87	-1,79	8,47
S14	25,58	20,47	28,60	28,40	12,93	13,59	20,51
S15	20,25	16,96	22,48	4,91	10,95	17,55	15,44
S16	2,79	-4,56	-0,55	5,27	7,41	-2,80	3,37
średnia	8,13	8,97	10,74	7,81	7,21	6,03	8,20

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, Św: dzień świąteczny; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej szwedzkiego OSP [378].

Tab. 4.3.2.6. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędów MAPE, [%].

Św.	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	18,87	17,87	13,70	14,10	10,04	2,39	11,14
S02	3,20	2,53	5,85	8,89	5,62	3,02	4,44
S03	27,65	34,31	30,06	29,42	27,28	3,60	22,19
S04	6,78	8,47	4,34	7,28	5,46	12,84	7,02
S05	25,58	30,41	26,30	17,41	-2,09	24,35	18,14
S06	7,53	13,67	22,87	5,83	2,44	9,39	9,68
S07	5,27	8,19	0,56	27,23	20,08	6,15	10,64
S08	23,00	13,43	13,31	17,17	13,09	18,05	15,15
S09	31,69	31,26	32,88	31,57	28,78	28,54	27,67
S10	30,08	32,67	28,19	2,18	27,22	30,21	22,94
S11	41,81	39,91	27,02	38,10	37,65	34,78	32,89
S12	0,42	26,49	27,80	24,82	25,53	21,66	19,82
S13	21,98	25,01	30,64	32,42	21,49	7,54	21,73
S14	48,14	44,51	51,23	28,84	17,71	47,98	36,06
S15	21,92	21,24	22,92	3,45	36,64	19,33	20,07
S16	6,39	8,12	8,43	16,64	10,26	3,53	9,91
średnia	20,02	22,38	21,63	19,09	17,95	17,08	18,09

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, Św: dzień świąteczny; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej szwedzkiego OSP [378].

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 05:00 (Tab. 4.3.2.6) dla dni świątecznych i niestandardowych wskazują, że opracowana metoda różni się efektywnością w najkorzystniejszym przypadku o 4,44% dla Święta 3 Króli.

4.3.3. System francuski

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej testowanej na danych historycznych systemu Francji dla godzin 00:00 – 05:00 (Tab. 4.3.3.1) wskazuje, że różni się ona skutecznością w najkorzystniejszym przypadku o 1,75% dla godziny 00:00.

Tab. 4.3.3.1. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w poszczególnych latach 2009 – 2018, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	2013	2014	2015	2016	2017	2018	2009 – 2018
00:00	2,48	2,34	1,09	0,98	1,41	2,20	1,75
01:00	3,59	4,04	3,61	3,53	2,99	3,54	3,57
02:00	2,99	3,18	2,67	2,74	2,22	2,77	2,81
03:00	3,67	4,10	3,88	3,93	3,63	4,14	3,89
04:00	3,54	3,91	4,11	4,22	4,09	4,49	4,02
05:00	3,40	3,55	3,89	4,12	3,96	4,35	3,76
<i>średnia</i>	3,28	3,52	3,21	3,25	3,05	3,58	3,30

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej francuskiego OSP [377].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej testowanej na danych historycznych systemu Francji dla godzin 06:00 – 23:00 (Tab. 4.3.3.2) wskazuje, że różni się ona skutecznością w najkorzystniejszym przypadku o 2,38% dla godziny 22:00.

Tab. 4.3.3.2. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w poszczególnych latach 2009 – 2018, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	2013	2014	2015	2016	2017	2018	2009 – 2018
06:00	5,97	6,12	6,42	6,35	6,36	6,71	6,08
07:00	8,92	9,03	9,35	9,13	9,16	9,47	8,96
08:00	9,20	9,33	9,54	9,47	9,48	10,02	9,30
09:00	8,51	8,37	8,64	8,54	8,59	9,13	8,48
10:00	7,84	7,70	7,98	7,86	7,88	8,50	7,82
11:00	7,75	7,56	7,85	7,93	7,93	8,38	7,74
12:00	7,88	7,85	8,07	8,10	7,99	8,46	7,88
13:00	7,40	7,86	7,63	7,54	7,28	8,44	7,53
14:00	7,70	8,22	8,00	7,93	7,75	8,65	7,87
15:00	7,75	8,29	8,25	8,09	7,94	8,72	7,98
16:00	7,04	7,59	7,61	7,55	7,33	8,05	7,38
17:00	5,57	5,92	6,13	6,21	6,12	6,60	5,98
18:00	4,41	4,71	5,18	5,15	5,13	5,51	4,91
19:00	5,16	5,64	5,50	5,46	5,55	6,28	5,45
20:00	4,80	5,18	4,95	5,01	4,75	5,64	4,91
21:00	4,40	4,79	4,83	4,75	4,57	5,21	4,61
22:00	2,11	2,13	2,49	2,82	2,57	2,78	2,38
23:00	3,72	3,87	3,25	3,29	2,93	3,43	3,38
<i>średnia</i>	6,45	6,68	6,76	6,73	6,63	7,22	6,59

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej francuskiego OSP [377].

Dni tygodnia, dni świąteczne i dni niestandardowe

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.3.3.3) w podziale na typy dni wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 0,56% dla czwartków.

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.3.3.3. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
00:00	0,39	7,54	-0,69	-0,41	-1,10	-0,65	7,16	1,14	3,25	7,15	4,73
01:00	1,15	9,68	1,41	1,20	1,32	1,46	8,80	2,95	5,13	8,62	6,11
02:00	0,07	8,72	0,73	0,58	0,69	0,88	7,99	2,16	4,43	8,60	7,10
03:00	0,99	9,62	1,51	1,40	1,66	2,49	9,61	3,03	6,05	9,57	8,68
04:00	1,65	9,15	1,06	1,06	1,37	3,57	10,25	2,86	6,91	10,43	8,99
05:00	4,57	6,64	-0,53	-0,48	0,05	5,63	10,48	2,05	8,05	11,71	9,99
średnia	1,47	8,56	0,58	0,56	0,66	2,23	9,05	2,36	5,64	9,35	7,60

Legenda: rob.: dni robocze; wee.: Weekend; Św.: dni świąteczne ruchome i nieruchome; Wig.: Wigilia Bożego Narodzenia, „-/++”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej francuskiego OSP [377].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.3.3.4) w podziale na typy dni wskazuje, że różni się ona jakością w najkorzystniejszym przypadku o 1,36% dla śród.

Tab. 4.3.3.4. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
06:00	15,31	3,12	-1,25	-1,18	-0,52	12,91	14,18	3,10	13,55	20,39	17,36
07:00	23,48	3,75	0,89	1,10	1,89	15,83	15,78	6,22	15,81	25,91	23,04
08:00	24,87	3,78	2,02	2,27	3,06	13,35	15,73	7,20	14,54	26,88	22,35
09:00	22,49	3,17	2,17	2,33	2,90	11,12	15,16	6,62	13,14	25,75	18,20
10:00	20,06	3,04	2,22	2,28	2,73	10,04	14,38	6,07	12,21	24,83	16,18
11:00	20,08	3,04	2,18	2,18	2,61	10,16	13,90	6,02	12,03	24,73	16,32
12:00	20,35	3,30	2,42	2,35	2,78	11,00	12,96	6,24	11,98	24,26	16,11
13:00	20,26	3,18	2,32	2,21	2,56	11,08	11,07	6,11	11,08	24,49	17,02
14:00	20,34	3,34	2,41	2,25	2,80	12,91	11,04	6,23	11,97	23,83	15,97
15:00	20,52	3,44	2,32	2,20	2,72	13,35	11,28	6,24	12,32	23,92	14,44
16:00	18,86	3,26	1,99	1,86	2,27	12,57	10,81	5,65	11,69	21,82	13,88
17:00	16,53	2,40	1,05	1,09	1,28	11,11	8,41	4,47	9,76	18,20	21,39
18:00	14,31	1,80	0,46	0,55	0,95	9,97	6,31	3,62	8,14	16,48	30,84
19:00	14,41	2,50	1,26	1,35	1,82	10,95	5,87	4,27	8,41	16,44	35,20
20:00	13,82	1,82	0,78	0,73	1,68	10,54	4,96	3,77	7,75	15,07	32,17
21:00	13,07	1,60	0,89	0,80	2,10	10,25	3,52	3,70	6,89	12,86	24,71
22:00	9,52	0,39	-0,24	-0,35	0,03	6,57	0,74	1,87	3,66	8,20	14,79
23:00	9,82	1,07	0,58	0,54	0,80	8,45	2,37	2,57	5,39	9,91	15,07
średnia	17,67	2,67	1,36	1,36	1,91	11,23	9,92	5,00	10,57	20,22	20,28

Legenda: rob.: dni robocze; wee.: Weekend; Św.: dni świąteczne ruchome i nieruchome; Wig.: Wigilia Bożego Narodzenia, „-/++”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej francuskiego OSP [377].

Dni świąteczne i dni niestandardowe

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.3.3.5) dla dni świątecznych i niestandardowych wskazują, że różni się ona skutecznością w najkorzystniejszym przypadku o 2,43% dla Święta Wniebowzięcia NMP.

Tab. 4.3.3.5. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].

Św.	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	2,77	6,33	7,09	2,98	8,17	-4,04	3,47
S02	3,02	2,69	4,43	4,69	2,49	1,96	3,04
S03	16,73	24,54	20,94	21,10	23,89	1,08	15,90
S04	5,64	9,24	6,01	0,91	2,78	0,42	4,14
S05	5,72	13,89	6,75	16,07	5,30	2,08	7,83
S06	9,68	14,65	16,97	0,12	3,95	16,20	9,65
S07	4,12	4,44	7,29	0,72	2,75	0,30	3,80
S08	8,40	10,41	10,85	10,81	10,04	17,99	10,93
S09	5,68	5,67	5,16	6,31	4,36	2,91	5,58
S10	2,31	3,03	5,04	-7,28	0,37	3,51	2,43
S11	9,01	13,68	19,95	1,82	7,76	10,05	10,47
S12	6,95	1,74	8,33	11,42	12,22	18,20	10,12
S13	-2,55	9,20	4,02	16,11	18,98	-0,58	8,31
S14	20,74	24,64	27,54	27,58	9,85	17,54	20,27
S15	14,43	14,95	20,21	5,94	7,35	20,59	14,07
S16	4,63	-0,19	-0,52	4,60	6,06	-1,25	4,19
średnia	7,33	9,93	10,63	7,75	7,90	6,69	8,39

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, Św: dzień świąteczny; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej francuskiego OSP [377].

Tab. 4.3.3.6. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].

Św.	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	18,34	17,55	17,86	-3,04	10,48	-2,95	8,46
S02	5,31	6,43	5,05	8,37	6,80	5,47	5,63
S03	29,19	33,58	30,18	30,19	25,15	1,19	21,78
S04	5,96	6,65	4,47	4,99	2,55	10,94	5,65
S05	21,09	29,48	23,66	19,16	-1,83	26,45	17,57
S06	10,15	11,84	19,98	6,97	3,10	9,30	9,62
S07	8,21	9,36	-2,29	27,17	18,40	8,47	10,90
S08	18,64	12,47	14,70	17,66	11,31	18,01	14,40
S09	29,20	31,13	33,37	34,94	28,84	28,20	27,81
S10	22,09	30,39	24,66	1,75	24,03	29,33	20,32
S11	34,10	40,11	25,74	37,14	32,57	34,80	30,78
S12	0,57	24,67	24,96	23,34	24,91	20,47	18,70
S13	19,02	28,12	20,51	33,22	20,98	6,79	20,23
S14	37,69	48,38	51,17	28,74	10,46	48,86	34,19
S15	19,78	20,05	21,49	3,12	36,62	19,43	19,36
S16	6,04	8,67	7,46	14,12	9,59	5,33	9,60
średnia	17,84	22,43	20,19	17,99	16,50	16,88	17,19

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, Św: dzień świąteczny; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej francuskiego OSP [377].

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.3.3.6) dla dni świątecznych i niestandardowych wskazują, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 5,63% dla Święta Trzech Króli.

4.4. Walidacja modelu ważonych współczynników funkcji autokorelacji cząstkowej – porównanie z wybranymi metodami autoregresyjnymi

4.4.1. Wybrane metody i modele prognozowania autoregresyjnego

W trzecim obszarze walidacyjnym (Tab. 4.4.1.1) przeprowadzono analizę wyników osiemdziesięciu modeli prognostycznych w ośmiu grupach metod zaliczanych do kategorii metod autoregresyjnych. Do tej grupy metod zaliczono metody wygładzania wykładniczego, metodę autoregresji rzędu pierwszego i wyższych rzędów, metodę regresji wielorakiej (z wykorzystaniem danych wyłącznie wynikających z szeregu czasowego i jego umiejscowienia w czasie kodowanych binarnie), metody autoregresyjne z opóźnieniami, metodę ARIMA, metodę prognozowania naiwnego, metodę najmniejszych kwadratów błędów (MNKB), metodę średniej kroczącej. Każdemu modelowi zaprezentowanemu w Tabeli 4.4.1.1 przyporządkowano T_b , T_o , T_c reprezentujące odpowiednio przybliżone czasy wyrażone w minutach: budowy modelu prognostycznego, kalibracji modelu prognostycznego i całkowity będący sumą dwóch wcześniejszych czasów. Wskazane czasy dla opracowanej nowej metody odzwierciedlono w Tabeli 4.4.1.1 i Tabeli 4.4.1.2.

Tab. 4.4.1.1. Wybrane metody i modele prognostyczne wobec metody ważonych współczynników funkcji autokorelacji cząstkowej w horyzoncie $n+1$ w podziale na grupy modeli i metod w okresie analizy 2009 – 2018.

Lp.	Model	Model szczegółowy	T_b	T_k	T_c	Grupa modeli	Grupa metod
1.	Holt 1	Model Holta 1 [$\alpha = 0,463; \beta = 0,463$]	1	3	4	Modele Holta	Metody wygładzania wykładniczego
2.	Holt 2	Model Holta 2 [$\alpha = 0,0876; \beta = 0,000$]	1	3	4		
3.	Holt 3	Model Holta 3 [$\alpha = 0,877; \beta = 0,003$]	1	3	4		
4.	Brown 1	Model Browna 1 [$y_n^p = y_1$]	1	3	4	Modele Browna	
5.	Brown 2	Model Browna 2 [$y_n^p = (y_1 + y_2 + y_3)/3$]	1	3	4		
6.	Brown 3	Model Browna 3 [$y_n^p = (y_1 + y_2 + y_3)/5$]	1	3	4		
7.	Winters – M 1	Model Wintersa multiplikatywny 1 [$\alpha = 0,957; \beta = 0,033; \gamma = 0,137$]	2	3	5	Modele Wintersa	
8.	Winters – M 2	Model Wintersa multiplikatywny 2 [$\alpha = 0,957; \beta = 0,033; \gamma = 0,167$]	2	3	5		
9.	Winters – A 1	Model Wintersa addytywny 1 [$\alpha = 0,957; \beta = 0,033; \gamma = 0,167$]	2	3	5		
10.	Winters – A 2	Model Wintersa addytywny 2 [$\alpha = 0,957; \beta = 0,033; \gamma = 0,157$]	2	3	5		
11.	AR (1) zz	Model liniowy autoregresji pierwszego poziomu (1) [zmienna zależna: $\beta_0 = 0,441; \beta_1 = 8,863$]	1	1	2	Modele autoregresji pierwszego rzędu	Metoda autoregresji rzędu pierwszego i wyższych rzędów
12.	AR (1) zc	Model liniowy autoregresji pierwszego poziomu (1) [zmienna zależna: $\beta_0 = 0,441; \beta_1 = 8,863$]	1	1	2		
13.	AR (1)	Model liniowy autoregresji pierwszego poziomu (1) [$\beta_0 = 0,059; \beta_1 = 8,866$]	1	1	2		
14.	Arwp (1)	Model liniowy autoregresji wyższego poziomu (poz. 1) [$a_0 = 0,059; a_1 = 0,866$]	1	1	2	Modele autoregresji wyższego rzędu	
15.	Arwp (2)	Model liniowy autoregresji wyższego poziomu (poz. 2) [$a_0 = 0,053; a_1 = 0,772; a_2 = 0,109$]	1	1	2		
16.	Arwp (3)	Model liniowy autoregresji wyższego poziomu (rzęd 3) [$a_0 = -0,064; a_1 = 0,794; a_2 = 0,264; a_3 = -0,201$]	1	1	2		
17.	Arwp (4)	Model liniowy autoregresji wyższego poziomu (poz. 4) [$a_0 = 0,080; a_1 = 0,741; a_2 = 0,333; a_3 = 0,007; a_4 = -0,262$]	1	1	2		

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Lp.	Model	Model szczegółowy	T_b	T_k	T_c	Grupa modeli	Grupa metod
18.	Arwp (5)	Model liniowy autoregresji wyższego poziomu (poz. 5) [$a_0 = 0,099$; $a_1 = 0,680$; $a_2 = 0,335$; $a_3 = 0,083$; $a_4 = -0,092$; $a_5 = -0,230$]	1	2	3		
19.	RW 1	Model regresji wielorakiej [godzina]	1	0	1	Modele regresji wielorakiej o danych (związanych wyłącznie z badanym szeregiem i jego powiązaniami z wpływem czasu) wejściowych kodowanych binarnie	Metoda regresji wielorakiej
20.	RW 2	Model regresji wielorakiej [lp. dnia]	1	0	1		
21.	RW 3	Model regresji wielorakiej [miesiąc]	1	0	1		
22.	RW 4	Model regresji wielorakiej [rok]	1	0	1		
23.	RW 5	Model regresji wielorakiej [dzień tygodnia]	1	0	1		
24.	RW 6	Model regresji wielorakiej [godziny indywidualne]	1	0	1		
25.	RW 7	Model regresji wielorakiej [dzień tygodnia indywidualnie]	1	0	1		
26.	RW 8	Model regresji wielorakiej [miesiąc indywidualnie]	1	0	1		
27.	RW 9	Model regresji wielorakiej [dni świąteczne i dni niestandardowe]	1	0	1		
28.	RW 10	Model regresji wielorakiej [godzina, data]	1	0	1		
29.	RW 11	Model regresji wielorakiej [lp. dnia, data]	1	0	1		
30.	RW 12	Model regresji wielorakiej [dzień tygodnia, data]	1	0	1		
31.	RW 13	Model regresji wielorakiej [miesiąc, data]	1	0	1		
32.	RW 14	Model regresji wielorakiej [dzień tygodnia, miesiąc, data]	1	0	1		
33.	RW 15	Model regresji wielorakiej [lp. dnia, dni świąteczne i dni niestandardowe, data]	1	0	1		
34.	RW 16	Model regresji wielorakiej [dzień tygodnia, dni świąteczne i dni niestandardowe, data]	1	0	1		
35.	RW 17	Model regresji wielorakiej [miesiąc, dni świąteczne i niestandardowe, data]	1	0	1		
36.	RW 18	Model regresji wielorakiej [dzień tygodnia, miesiąc, dni świąteczne i niestandardowe, data]	1	0	1		
37.	ARlag 1	Model Autoregresji [24 h. opóźnienie]	1	0	1	Modele autoregresyjne z opóźnieniami (wynikającymi wyłącznie z charakteru badanego szeregu)	Metody auto-regresyjne
38.	ARlag 2	Model autoregresji [48 h. opóźnienie]	1	0	1		
39.	ARlag 3	Model autoregresji [72 h. opóźnienie]	1	0	1		
40.	ARlag 4	Model autoregresji [96 h. opóźnienie]	1	0	1		
41.	ARlag 5	Model autoregresji [120 h. opóźnienie]	1	0	1		
42.	ARlag 6	Model autoregresji [144 h. opóźnienie]	1	0	1		
43.	ARlag 7	Model autoregresji [168 h. opóźnienie]	1	0	1		
44.	ARlag 8	Model autoregresji [192 h. opóźnienie]	1	0	1		
45.	ARlag 9	Model autoregresji [216 h. opóźnienie]	1	0	1		
46.	ARlag 10	Model autoregresji [240 h. opóźnienie]	1	0	1		
47.	ARlag 11	Model autoregresji [264 h. opóźnienie]	1	0	1		
48.	ARlag 12	Model autoregresji [268 h. opóźnienie]	1	0	1		
49.	ARlag 13	Model autoregresji [312 h. opóźnienie]	1	0	1		
50.	ARlag 14	Model autoregresji [336 h. opóźnienie]	1	0	1		
51.	ARlag 15	Model autoregresji [344 h. opóźnienie]	1	0	1		
52.	ARlag 16	Model autoregresji [360 h. opóźnienie]	1	0	1		
53.	ARlag 17	Model autoregresji [ARlag 1 i 2]	1	0	1		
54.	ARlag 18	Model autoregresji [ARlag 1 i 2 i 3]	1	0	1		
55.	ARlag 19	Model autoregresji [ARlag 1 i 2 i 3 i 4]	1	0	1		
56.	ARlag 20	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5]	1	0	1		
57.	ARlag 21	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6]	1	0	1		
58.	ARlag 22	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6 i 7]	1	0	1		
59.	ARlag 23	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6 i 7 i 8]	1	0	1		
60.	ARlag 24	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6 i 7 i 8 i 9]	1	0	1		
61.	ARlag 25	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6 i 7 i 8 i 9 i 10]	2	0	2		
62.	ARlag 26	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6 i 7 i 8 i 9 i 10 i 11]	2	0	2		
63.	ARlag 27	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6 i 7 i 8 i 9 i 10 i 11 i 12]	2	0	2		
64.	ARlag 28	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6 i 7 i 8 i 9 i 10 i 11 i 12 i 13]	2	0	2		
65.	ARlag 29	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6 i 7 i 8 i 9 i 10 i 11 i 12 i 13 i 14]	2	0	2		
66.	ARlag 30	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6 i 7 i 8 i 9 i 10 i 11 i 12 i 13 i 14 i 15]	2	0	2		
67.	ARlag 31	Model autoregresji [ARlag 1 i 2 i 3 i 4 i 5 i 6 i 7 i 8 i 9 i 10 i 11 i 12 i 13 i 14 i 15 i 16]	2	0	2		
68.	ARlag 32	Model autoregresji [ARlag 1 i 7]	1	0	1		
69.	ARlag 33	Model autoregresji [ARlag 7 i 14]	1	0	1		
70.	ARlag 34	Model autoregresji [ARlag 7 i 8]	1	0	1		
71.	ARlag 35	Model autoregresji [ARlag 7 i 8 i 14]	1	0	1		
72.	ARlag 36	Model autoregresji [ARlag 1 i 7 i 15]	1	0	1		
73.	ARlag 37	Model autoregresji [ARlag 7 i 14 i 15]	1	0	1		

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Lp.	Model	Model szczegółowy	T_b	T_k	T_c	Grupa modeli	Grupa metod
74.	ARlag 38	Model autoregresji [ARlag 7 i 8 i 15]	1	0	1		
75.	ARlag 39	Model autoregresji [ARlag 7 i 8 i 14 i 15]	1	0	1		
76.	ARIMA	Model ARIMA(1,1,2)(1,0,2)168	2	10	12	Model autoregresji i średniej kroczącej	ARIMA
77.	MN(-7)	Model wykorzystujący metodę naiwną z opóźnieniem 7 dób [$y_n^p = y_{n-7}$]	1	0	1	Modele naiwne	Naiwne
78.	MN(-1)	Model wykorzystujący metodę naiwną z opóźnieniem 1 doby [$y_n^p = y_{n-1}$]	1	0	1		
79.	MNKB	Metoda Najmniejszych Kwadratów Błędów	10	10	20	Model najmniejszych kwadratów błędów	Metoda MNKB
80.	SK20	Średnia krocząca dwuokresowa [$y_n^p = (y_{n-1} + y_{n-2})/2$]	1	0	1	Model średniej kroczącej	Metoda średniej kroczącej

Legenda: T_b : czas budowy modelu prognostycznego [minuty]; T_k : czas kalibracji parametrów modelu [minuty]; T_c : czas całkowity będący sumą czasu budowy modelu prognostycznego i kalibracji jego parametrów [minuty].

Uwaga: czas T_b dotyczy modeli już zbudowanych, skalibrowanych i wyeksportowanych jako niezależne modele prognostyczne, które zasilone zostały w nowe dane wejściowe i wymagane jest podjęcie standardowych czynności ich obsługi, które mogą różnić się w zależności od stosowanych nawyków, zastosowanego oprogramowania i sposobu zasilania modeli prognostycznych zaktualizowanymi danymi wejściowymi; czas T_k związany jest z dodatkowymi działaniami wynikającymi z wczytania do modelu prognostycznego nowych danych wejściowych.

Źródło: Opracowanie własne.

4.4.2. Skuteczność i ranking wybranych metod i modeli prognozowania autoregresyjnego

Tabela 4.4.2.1 prezentuje ranking (kolumna Rank.), wybranych modeli autoregresyjnych (pozycje opisywane liczbami porządkowymi w kolumnie pierwszej) wzbogaconych o informacje dotyczące modelu stosowanego przez PSE S.A. (A1) oraz zaproponowanej metody ważonych współczynników funkcji autokorelacji cząstkowej (A2). Modele prognostyczne z przypisanymi numerami porządkowymi oraz ich skutecznością i rankingiem wskazują, że najskuteczniejszą metodą z grupy metod wybranych jest metoda ARIMA(p,q,d)(P,Q,D)m, następnie metoda naiwna z opóźnieniem 7 dób i metoda średniej kroczącej dwuokresowej. Do analiz porównawczych z jakością opracowanej metody ważonych współczynników funkcji autokorelacji cząstkowej zakwalifikowano model bazujący na metodzie ARIMA, metody naiwnej z opóźnieniem 7 dób i z opóźnieniem 1 doby. Ostatni z zakwalifikowanych modeli do analiz porównawczych wynika z przynależności do grupy metod o drugiej największej skuteczności oraz niewielkiej różnicy do trzeciej najskuteczniejszej metody w rankingu jakości. Analiza współmierności i racjonalności nakładów względem oczekiwanego poziomu jakości, odnosząca się do pierwszej hipotezy rozprawy, wspomagana jest analizą porównawczą czasochłonności opracowanej metody wobec osiemdziesięciu wybranych modeli prognostycznych autoregresyjnych. Z przedmiotowej analizy wyłączono model stosowany przez PSE S.A., dla którego pozyskanie jednoznacznej informacji o szczegółowych czasach uwzględnianych w analizie porównawczej było nieosiągalne. Analiza czasochłonności procesów prognostycznych dla poszczególnych modeli prognostycznych uwzględnia ich gotowe modele matematyczne, czas importu danych wejściowych dla całego dziesięcioletniego okresu analizy, wskazanie zmiennej lub zmiennych objaśniających analizowany proces, przeprowadzenie podstawowej kalibracji parametrów opisujących poszczególne modele, wykonanie prognozy

dla prognozowanej doby z rozdzielczością godzinową oraz wyeksportowanie wyników prognozy do zewnętrznego pliku.

Tab. 4.4.2.1. Skuteczność prognozowania dla wybranych metod prognostycznych wraz z czasochłonnością ich opracowania wobec skuteczności PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej w horyzoncie $n+1$ w okresie analizy 2009 – 2018 wyrażona wartościami błędu MAPE, [%].

Lp.	Model	MAPE	Rank.	T_b	T_o	T_c	Lp.	Model	MAPE	Rank.	T_b	T_o	T_c
A1	PSE S.A.	0,82	n.d.	b.d.	b.d.	b.d.	n.d.	n.d.	n.d.	n.d.	n.d.	n.d.	n.d.
A2	Ważonych współczynników funkcji autokorelacji cząstkowej	8,29	n.d.	1	0	1	n.d.	n.d.	n.d.	n.d.	n.d.	n.d.	n.d.
76.	ARIMA(1,1,2) (1,0,2)168	2,58	1	2	10	12	68.	ARlag 32	8,83	41	1	0	1
77.	MN(-7)	4,15	2	1	0	1	72.	ARlag 36	8,83	42	1	0	1
80.	SK20	4,97	3	1	0	1	50.	ARlag 14	8,97	43	1	0	1
42.	ARlag 6	5,49	4	1	0	1	79.	MNKB	8,99	44	10	10	20
49.	ARlag 13	6,31	5	1	0	1	56.	ARlag 20	9,35	45	1	0	1
13.	AR (1)	7,10	6	1	1	2	41.	ARlag 5	9,43	46	1	0	1
78.	MN(-1)	7,14	7	1	0	1	48.	ARlag 12	9,88	47	1	0	1
57.	ARlag 21	7,58	8	1	0	1	55.	ARlag 19	10,41	48	1	0	1
17.	Arwp (4)	7,62	9	1	1	2	54.	ARlag 18	10,58	49	1	0	1
15.	Arwp (2)	7,63	10	1	1	2	37.	ARlag 1	10,76	50	1	0	1
18.	Arwp (5)	7,63	11	1	2	3	53.	ARlag 17	10,77	51	1	0	1
16.	Arwp (3)	7,64	12	1	1	2	40.	ARlag 4	11,29	52	1	0	1
67.	ARlag 31	8,02	13	2	0	2	44.	ARlag 8	11,30	53	1	0	1
59.	ARlag 23	8,04	14	1	0	1	38.	ARlag 2	11,42	54	1	0	1
60.	ARlag 24	8,04	15	1	0	1	52.	ARlag 16	11,51	55	1	0	1
2.	Holt 2	8,05	16	1	3	4	39.	ARlag 3	11,57	56	1	0	1
3.	Holt 3	8,05	17	1	3	4	47.	ARlag 11	11,58	57	1	0	1
61.	ARlag 25	8,05	18	2	0	2	45.	ARlag 9	11,72	58	1	0	1
62.	ARlag 26	8,06	19	2	0	2	46.	ARlag 10	11,80	59	1	0	1
64.	ARlag 28	8,06	20	2	0	2	23.	RW 5	14,92	60	1	0	1
63.	ARlag 27	8,10	21	2	0	2	11.	AR (1) zz	14,93	61	1	1	2
8.	Winters – M 2	8,11	22	2	3	5	12.	AR (1) zc	14,93	62	1	1	2
7.	Winters – M 1	8,12	23	2	3	5	31.	RW 13	15,02	63	1	0	1
9.	Winters – A 1	8,12	24	2	3	5	20.	RW 2	15,06	64	1	0	1
10.	Winters – A 2	8,12	25	2	3	5	28.	RW 10	15,07	65	1	0	1
66.	ARlag 30	8,12	26	2	0	2	34.	RW 16	15,10	66	1	0	1
65.	ARlag 29	8,20	27	2	0	2	25.	RW 7	15,17	67	1	0	1
73.	ARlag 37	8,37	28	1	0	1	21.	RW 3	15,20	68	1	0	1
75.	ARlag 39	8,41	29	1	0	1	35.	RW 17	15,20	69	1	0	1
69.	ARlag 33	8,43	30	1	0	1	26.	RW 8	15,31	70	1	0	1
71.	ARlag 35	8,48	31	1	0	1	51.	ARlag 15	15,45	71	1	0	1
74.	ARlag 38	8,48	32	1	0	1	27.	RW 9	15,49	72	1	0	1
1.	Holt 1	8,49	33	1	3	4	30.	RW 12	15,49	73	1	0	1
43.	ARlag 7	8,50	34	1	0	1	32.	RW 14	16,63	74	1	0	1
58.	ARlag 22	8,51	35	1	0	1	19.	RW 1	16,66	75	1	0	1
70.	ARlag 34	8,56	36	1	0	1	36.	RW 18	16,93	76	1	0	1
14.	Arwp (1)	8,61	37	1	1	2	29.	RW 11	17,63	77	1	0	1
4.	Brown 1	8,69	38	1	3	4	22.	RW 4	18,08	78	1	0	1
5.	Brown 2	8,69	39	1	3	4	24.	RW 6	18,34	79	1	0	1
6.	Brown 3	8,69	40	1	3	4	33.	RW 15	18,68	80	1	0	1

Legenda: Rank: ranking; T_b : czas budowy modelu prognostycznego [minuty]; T_i : czas kalibracji parametrów modelu [minuty]; T_c : czas całkowity będący sumą czasu budowy modelu prognostycznego i kalibracji jego parametrów [minuty]; n.d.: nie dotyczy; b.d.: brak danych.

Uwaga: czas T_b dotyczy modeli już zbudowanych, skalibrowanych i wyeksportowanych jako niezależne modele prognostyczne, które zasilone zostały w nowe dane wejściowe i wymagane jest podjęcie standardowych czynności ich obsługi, które mogą różnić się w zależności od stosowanych nawyków, zastosowanego oprogramowania i sposobu zasilania modeli prognostycznych zaktualizowanymi danymi wejściowymi; czas T_c związany jest z dodatkowymi działaniami wynikającymi z wczytania do modelu prognostycznego nowych danych wejściowych.

Źródło: Opracowanie własne.

Wyniki analizy porównawczej czasochłonności opracowywania poszczególnych modeli prognostycznych w porównaniu do opracowanej metody wskazują, że opracowany model zajmuje pierwsze miejsce w rankingu czasu budowy modelu prognostycznego

(ok. 1 minuta wraz z 67 modelami wybranych metod), pierwsze miejsce w rankingu kalibracji modelu prognostycznego (0 minut wraz z 60 modelami wybranych metod) oraz pierwsze miejsce w rankingu sumy wskazanych czasów (ok. 1 minuta wraz z 54 modelami wybranych metod). Modele niedostępne w pakiecie STATISTICA[®] opracowano w języku R sprzężonym z tym pakietem i z wykorzystaniem MS Excel[®].

Wyniki symulacji uzyskano z zastosowaniem komputera przenośnego o następujących parametrach: procesor (Procesor: Intel[®] Core™ i5 – 8350 CPU@ 1,70 GHz, pamięć RAM: 16,0 GB, typ systemu: x64; system operacyjny Windows 10, przestrzeń dyskowa: 500 GB) z zachowaniem niezmienności wskazanych parametrów w czasie prowadzonych badań i zachowaniem pełnej wydajności urządzenia.

4.4.3. Skuteczność prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej na tle metody ARIMA

Opracowany model ARIMA(1,1,2)(1,0,2)₁₆₈ został wybrany na podstawie testów dla poszczególnych parametrów tego modelu (p,q,d), (P,Q,D) i opóźnienia czasowego oznaczonego symbolem *m*. Opóźnienie czasowe testowane było w zakresie od doby poprzedniej (*m*=24) do 35 dób poprzedzających (*m*=840). Wartości pozostałych parametrów testowane były w zakresie: p<1;4>, q<0;4>, d<0;2>, P<0,4>, Q<0;4>, D<0;2>. Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej testowanej na danych historycznych KSE dla godzin 00:00 – 05:00 (Tab. 4.4.3.1) w porównaniu do prognoz uzyskanych dla modelu ARIMA wskazuje, że opracowana metoda różni się skutecznością w najkorzystniejszym przypadku dla godziny 02:00 na poziomie 4,25%. Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej testowanej na danych historycznych KSE dla godzin 06:00 – 23:00 (Tab. 4.4.3.2) w porównaniu do prognoz uzyskanych dla modelu ARIMA wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku dla godziny 07:00 na poziomie 9,19%.

Tab. 4.4.3.1. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie *n*+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
00:00	4,76	4,91	4,64	4,82	4,92	4,92	4,88	5,13	4,77	5,05	4,88
01:00	4,36	4,45	4,25	4,33	4,36	4,39	4,50	4,77	4,36	4,72	4,45
02:00	4,25	4,22	4,13	4,07	4,16	4,13	4,31	4,55	4,11	4,50	4,25
03:00	4,21	4,24	4,19	4,03	4,22	4,27	4,37	4,62	4,29	4,64	4,31
04:00	4,38	4,17	4,22	3,95	4,30	4,32	4,42	4,59	4,51	4,79	4,37
05:00	4,94	4,76	4,75	4,76	4,97	4,98	5,21	5,22	5,17	5,64	5,04
<i>średnia</i>	4,48	4,46	4,36	4,33	4,49	4,50	4,62	4,81	4,53	4,89	4,55

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.4.3.2. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
06:00	7,29	7,39	7,34	7,52	7,83	7,83	8,14	7,73	7,72	8,18	7,70
07:00	9,42	8,84	8,75	8,99	9,27	9,31	9,67	9,08	9,12	9,52	9,19
08:00	9,47	8,54	8,22	8,56	8,81	8,77	9,24	8,65	8,74	9,31	8,83
09:00	8,40	7,52	7,14	7,55	7,68	7,54	8,05	7,56	7,59	8,05	7,71
10:00	7,41	6,63	6,22	6,57	6,70	6,49	6,94	6,68	6,65	7,16	6,74
11:00	7,36	6,57	6,15	6,56	6,64	6,42	6,82	6,73	6,57	7,18	6,70
12:00	7,27	6,43	6,12	6,50	6,57	6,34	6,77	6,67	6,45	7,11	6,62
13:00	7,13	6,30	6,08	6,38	6,47	6,22	6,66	6,52	6,28	7,01	6,50
14:00	7,08	6,27	6,13	6,36	6,44	6,30	6,61	6,55	6,36	7,00	6,51
15:00	7,02	6,31	6,17	6,43	6,56	6,41	6,73	6,60	6,39	7,17	6,58
16:00	6,37	5,93	5,81	5,98	6,08	5,90	6,22	6,11	5,94	6,69	6,10
17:00	5,84	5,38	5,23	5,33	5,56	5,22	5,70	5,56	5,32	6,01	5,51
18:00	4,92	4,74	4,44	4,54	4,85	4,60	5,04	4,74	4,70	5,23	4,78
19:00	4,40	4,36	4,10	4,10	4,36	4,36	4,70	4,46	4,42	4,95	4,42
20:00	4,47	4,33	4,21	4,10	4,41	4,45	4,80	4,44	4,36	4,89	4,45
21:00	4,27	4,02	3,98	3,93	4,13	4,16	4,45	4,21	4,09	4,44	4,17
22:00	3,52	3,40	3,25	3,31	3,43	3,36	3,61	3,46	3,35	3,61	3,43
23:00	3,43	3,31	3,06	3,22	3,24	3,24	3,49	3,24	3,20	3,37	3,28
średnia	6,39	5,90	5,69	5,88	6,06	5,94	6,31	6,06	5,96	6,49	6,07

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Automatyzacja analizy dla całego dziesięcioletniego okresu wykonana została za pomocą skryptu w natywnym języku programowania STATISTICA®, natomiast obsługa danych do postaci niezbędnej dla wykonania porównań pomiędzy modelami została opracowana w języku R sprzęgniętym z pakietem STATISTICA®.

Dni tygodnia, dni świąteczne i dni niestandardowe

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.4.3.3) w podziale na typy dni w porównaniu do prognoz uzyskanych dla modelu ARIMA wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 1,67%, dla czwartków.

Tab. 4.4.3.3. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
00:00	3,33	11,15	2,71	2,11	2,21	2,60	10,08	4,32	6,29	9,42	4,51
01:00	2,09	10,42	2,34	1,75	2,03	2,57	9,96	3,77	6,15	8,50	3,15
02:00	1,45	9,93	2,08	1,66	1,90	2,67	10,03	3,44	6,25	8,13	2,37
03:00	1,42	9,80	1,91	1,62	1,85	3,10	10,46	3,36	6,66	7,81	2,32
04:00	2,35	9,29	1,57	1,45	1,68	3,76	10,46	3,31	7,00	6,95	1,96
05:00	6,66	7,71	1,32	1,46	1,28	6,07	10,72	3,64	8,51	5,21	1,85
średnia	2,88	9,72	1,99	1,67	1,82	3,46	10,28	3,64	6,81	7,67	2,69

Legenda: rob.: dni robocze; wee.: Weekend; Św.: dni świąteczne ruchome i nieruchome; Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.4.3.4. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
06:00	17,94	4,11	1,86	2,31	0,84	12,90	13,86	5,11	14,14	3,56	1,85
07:00	23,94	2,17	2,39	2,93	1,05	15,98	15,86	6,03	17,09	3,21	3,80
08:00	24,31	1,00	2,32	2,83	1,09	13,74	16,45	5,87	16,19	4,17	4,57
09:00	21,78	0,42	2,11	2,44	0,83	10,74	15,58	5,13	14,13	5,04	4,20
10:00	19,24	0,34	1,99	2,01	0,63	8,87	14,13	4,52	12,32	5,26	3,81
11:00	19,34	0,27	1,93	1,97	0,53	9,25	13,60	4,50	12,19	4,88	3,50
12:00	19,35	0,27	1,90	1,86	0,49	10,02	12,47	4,48	11,98	4,24	2,69
13:00	19,21	0,20	1,91	1,66	0,42	10,58	11,53	4,39	11,79	3,89	2,21
14:00	19,34	0,25	1,95	1,60	0,45	11,64	10,35	4,43	11,71	3,51	1,94
15:00	19,53	0,17	1,82	1,45	0,37	12,09	10,58	4,43	11,92	3,32	2,12
16:00	17,97	0,16	1,43	1,11	0,10	11,55	10,38	3,99	11,38	3,07	2,29
17:00	16,40	0,09	1,22	0,88	-0,03	11,00	9,01	3,59	10,32	1,88	2,64
18:00	14,62	-0,03	0,95	0,75	-0,27	9,99	7,35	3,09	8,94	0,45	3,11
19:00	13,79	0,03	0,83	0,74	-0,10	10,05	5,50	2,96	8,02	-0,25	2,97
20:00	13,83	0,21	0,86	0,93	0,45	10,16	4,65	3,16	7,64	0,05	2,44
21:00	13,16	0,19	1,08	0,99	0,90	9,71	3,13	3,16	6,67	0,27	2,12
22:00	10,70	0,36	1,05	0,74	0,54	8,25	2,34	2,59	5,53	0,44	2,00
23:00	9,97	0,45	0,83	0,77	0,31	8,21	2,40	2,38	5,53	0,23	0,83
srednia	17,47	0,59	1,58	1,55	0,48	10,82	9,95	4,10	10,97	2,62	2,73

Legenda: rob.: dni robocze; wee.: Weekend; Św.: dni świąteczne ruchome i nieruchome; Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.4.3.4) w podziale na typy dni jest skuteczniejsze w porównaniu do prognoz uzyskanych dla modelu ARIMA dla wtorków (godzina 18:00; 0,03%), dla piątków (godziny 17:00 – 19:00; 0,03%, 0,27%, 0,10%) oraz dla dni świątecznych (godzina 19:00; 0,25%). Najmniejsza degresja skuteczności w całym okresie analizy, na poziomie 0,48%, otrzymywana jest dla piątków, a największa, na poziomie 17,47%, dla poniedziałków.

Dni świąteczne i dni niestandardowe

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.4.3.5 i Tab. 4.4.3.6) dla dni świątecznych w porównaniu do prognoz uzyskanych dla modelu ARIMA wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 1,11%, dla Święta Bożego Ciała.

Tab. 4.4.3.5. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
00:00	0,10	3,76	19,28	10,23	7,13	13,79	6,72	10,56
01:00	-0,01	3,33	16,21	8,49	6,57	12,98	5,76	10,92
02:00	2,54	3,20	17,62	5,28	6,15	12,55	4,39	11,01
03:00	5,62	3,13	18,53	1,73	5,80	12,18	2,94	11,65
04:00	8,50	2,94	17,66	-1,49	5,60	11,80	-0,04	12,82
05:00	9,83	3,26	15,54	-8,55	4,35	11,22	-5,40	14,28
srednia	4,43	3,27	17,47	2,61	5,93	12,42	2,40	11,87

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

W pojedynczych godzinach zakresu godzinowego uzyskuje się poprawę jakości dla godziny 01:00 (0,01%) dla Nowego Roku, poprawę efektywności dla godzin 04:00 i 05:00, w przedziale od 1,49% do 8,55% dla drugiego dnia Świąt Wielkiej Nocy oraz dla godzin 04:00 i 05:00 (od 0,04% do 5,40%) dla Święta 3. Maja.

Tab. 4.4.3.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
00:00	1,44	3,52	9,28	7,93	4,51	17,70	20,11	2,94
01:00	1,56	2,99	9,28	8,09	3,15	16,95	17,08	1,48
02:00	1,67	2,75	8,89	7,81	2,37	16,42	15,16	1,50
03:00	1,69	3,32	8,73	7,92	2,32	15,18	13,00	1,14
04:00	0,28	3,73	8,65	7,19	1,96	14,78	9,77	0,83
05:00	0,02	3,30	9,24	5,59	1,85	13,10	6,11	1,48
średnia	1,11	3,27	9,01	7,42	2,69	15,69	13,54	1,56

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.4.3.7 i Tab. 4.4.3.8) dla dni świątecznych daje poprawę skuteczności w porównaniu do prognoz uzyskanych dla modelu ARIMA.

Tab. 4.4.3.7. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
06:00	12,68	5,27	17,58	-28,43	6,40	12,93	-9,92	18,68
07:00	16,25	6,39	19,95	-40,35	7,37	13,59	-11,99	21,59
08:00	19,85	6,04	22,11	-39,86	7,29	12,27	-10,93	21,86
09:00	20,86	5,14	23,16	-33,11	6,79	10,78	-8,42	20,60
10:00	19,97	4,47	23,18	-28,28	5,92	9,37	-7,25	19,04
11:00	18,10	4,36	23,43	-29,73	5,29	9,44	-7,86	18,91
12:00	15,78	4,35	21,94	-30,33	5,08	9,13	-8,19	17,95
13:00	15,31	4,37	20,44	-28,90	4,56	8,88	-8,21	17,08
14:00	14,66	4,34	17,92	-27,89	5,02	8,38	-8,74	15,61
15:00	14,67	4,39	17,94	-28,81	5,00	8,49	-9,34	15,60
16:00	13,04	3,92	18,31	-27,58	4,71	7,68	-9,78	15,67
17:00	7,42	3,59	16,59	-27,15	4,25	6,96	-10,08	14,47
18:00	3,46	3,22	13,48	-26,81	3,79	5,97	-9,88	12,52
19:00	2,24	3,10	9,82	-24,27	2,72	4,64	-10,54	10,28
20:00	2,11	3,11	9,18	-20,66	2,49	3,56	-9,69	8,34
21:00	2,05	2,83	6,53	-17,44	2,66	3,70	-5,97	5,89
22:00	2,13	2,31	4,25	-13,45	2,08	3,85	-5,82	5,00
23:00	2,93	2,14	1,90	-13,10	1,79	3,21	-6,06	5,18
średnia	11,31	4,07	15,98	-27,01	4,62	7,94	-8,82	14,68

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.4.3.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
06:00	0,73	2,25	7,47	6,56	1,85	11,15	-0,23	6,51
07:00	2,03	1,26	8,04	8,02	3,80	10,75	-3,78	11,56
08:00	2,29	1,00	9,24	8,82	4,57	11,80	-1,71	12,70
09:00	2,32	0,82	9,15	8,27	4,20	13,63	-0,17	10,63
10:00	2,15	1,14	8,90	7,48	3,81	14,18	0,67	8,95
11:00	2,11	1,42	8,74	7,65	3,50	14,19	-0,74	8,97
12:00	2,23	1,46	8,63	7,44	2,69	13,05	-1,83	8,98
13:00	1,78	1,29	7,88	7,13	2,21	12,45	-1,89	8,71
14:00	1,90	1,29	7,34	6,90	1,94	12,26	-2,06	8,65
15:00	1,66	1,01	7,97	6,91	2,12	11,91	-1,72	9,07
16:00	1,11	1,00	10,05	6,65	2,29	12,21	-3,38	5,38
17:00	0,72	0,77	10,96	5,91	2,64	12,38	-9,45	-1,48
18:00	0,46	0,56	7,37	4,68	3,11	11,95	-13,13	-3,78
19:00	0,56	0,78	6,35	4,34	2,97	10,70	-14,30	2,24
20:00	0,48	1,78	5,73	3,92	2,44	9,99	-12,54	12,27
21:00	0,70	0,90	4,98	3,64	2,12	9,45	-10,17	14,54
22:00	1,04	0,38	4,82	3,17	2,00	7,97	-6,73	10,21
23:00	0,15	0,40	4,58	2,59	0,83	6,08	-4,27	4,27
średnia	1,36	1,08	7,68	6,11	2,73	11,45	-4,86	7,69

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Największą poprawę skuteczności, średnio dla tych godzin, na poziomie 27,01%, uzyskuje się dla drugiego dnia Świąt Wielkiej Nocy, a następnie dla Święta 3. Maja (8,82%) i dla drugiego dnia Świąt Bożego Narodzenia (4,86%). Dla trzech wskazanych dni świątecznych odnotowywana jest poprawa efektywności prognozowania dla wszystkich godzin ze wskazanego zakresu. Dla Nowego Roku poprawa jakości prognozowania odnotowywana jest dla godzin 17:00 i 18:00 i kształtuje się odpowiednio na poziomie 1,48% i 3,78%. Największą regresją skuteczności prognoz charakteryzuje się drugi dzień Świąt Wielkiej Nocy (15,98%).

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.4.3.9) dla dni świątecznych i niestandardowych wskazują na poprawę jakości dla większości analizowanych dni świątecznych w poszczególnych latach analizy. Korzystna tendencja związana z poprawą jakości w ostatnich trzech latach analizy odnotowywana jest dla drugiego dnia Świąt Wielkanocnych (odpowiednio o 2,36%, 0,49% i 0,51%). Najmniejszą regresję skuteczności (1,11%) w całym okresie analizy uzyskuje się dla Bożego Ciała, a największą (17,47%) dla Wielkanocy.

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.4.3.10) dla dni świątecznych i niestandardowych dają poprawę efektywności dla całego okresu analizy. Największa poprawa efektywności (27,01%) otrzymywana jest dla drugiego dnia Świąt Wielkanocnych, następnie dla Święta 3 maja (8,82%) i dla drugiego dnia Świąt Bożego Narodzenia (4,86%).

Tab. 4.4.3.9. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].

Św.	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	6,59	9,16	7,73	-1,01	0,79	4,25	6,04	2,28	7,55	0,92	4,43
S02	0,00	0,00	6,22	2,09	3,81	4,21	4,84	5,50	3,05	2,96	3,27
S03	21,05	11,47	22,54	18,82	17,98	21,46	17,55	20,77	22,18	0,92	17,47
S04	4,56	10,63	5,04	1,74	0,25	3,34	3,94	-2,36	-0,49	-0,51	2,61
S05	7,88	8,45	10,28	-2,59	4,01	9,95	3,59	15,96	2,82	-1,03	5,93
S06	23,74	15,81	1,08	15,29	13,05	15,12	17,42	1,11	4,48	17,10	12,42
S07	9,89	-0,56	0,03	-1,18	2,10	5,13	9,12	-0,45	1,41	-1,52	2,40
S08	5,39	11,80	12,35	12,31	10,78	12,27	11,08	10,83	12,88	19,05	11,87
S09	3,32	3,07	0,49	1,01	-0,68	-0,84	-0,54	3,80	0,49	0,96	1,11
S10	6,00	9,71	2,38	0,68	2,19	2,59	8,02	0,26	-0,04	0,89	3,27
S11	17,08	6,16	1,85	9,07	6,37	13,48	21,00	0,32	5,57	9,20	9,01
S12	-0,56	6,12	4,76	14,97	3,56	-0,34	6,94	8,47	11,82	18,47	7,42
S13	1,21	4,62	9,45	-6,39	-4,72	3,93	0,93	10,37	14,50	-6,98	2,69
S14	14,28	19,39	17,01	7,75	19,82	17,64	21,27	23,70	4,33	11,70	15,69
S15	24,99	14,48	-1,09	21,29	15,29	12,95	20,27	-0,44	10,02	17,64	13,54
S16	2,54	1,87	1,18	1,15	3,49	-2,70	-1,64	3,78	6,54	-0,60	1,56
średnia	9,25	8,26	6,33	5,94	6,13	7,65	9,37	6,49	6,69	5,57	7,17

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, Św: dzień świąteczny; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.4.3.10. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].

Św.	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	16,66	13,97	16,44	8,06	13,05	15,20	13,00	10,75	9,47	-3,55	11,31
S02	0,00	0,00	5,98	4,70	4,66	5,12	1,19	7,22	7,04	4,82	4,07
S03	17,44	17,81	20,81	17,19	19,16	20,49	17,09	16,66	16,72	-3,55	15,98
S04	-27,91	-28,67	-26,03	-29,09	-28,88	-31,26	-30,12	-32,02	-28,66	-7,44	-27,01
S05	8,27	17,55	9,83	3,53	3,26	5,42	3,79	12,66	-24,14	6,06	4,62
S06	24,66	16,15	3,28	6,17	5,66	8,26	22,53	-7,65	-5,17	5,46	7,94
S07	-1,27	-24,69	-24,52	-10,17	-13,78	4,52	-1,23	3,71	-4,78	-15,95	-8,82
S08	14,59	11,62	11,73	12,69	20,95	13,23	13,15	16,71	12,48	19,66	14,68
S09	2,13	2,55	0,21	1,41	1,90	-1,89	1,70	3,78	-0,83	2,60	1,36
S10	14,95	14,60	-22,17	0,17	0,17	6,65	15,83	-25,89	3,71	2,83	1,08
S11	18,94	-26,71	7,87	6,79	9,45	23,57	18,94	7,16	6,34	4,41	7,68
S12	3,82	-0,35	5,79	17,87	-20,28	5,55	5,89	4,38	19,39	19,08	6,11
S13	2,73	5,14	18,34	-19,73	2,55	3,40	2,71	20,25	12,16	-20,27	2,73
S14	11,17	24,44	16,26	13,97	10,05	13,61	15,80	17,49	-24,63	16,35	11,45
S15	11,62	5,55	-29,95	-1,27	-6,60	-2,81	7,66	-33,79	7,48	-6,47	-4,86
S16	8,28	8,41	12,56	2,79	3,30	5,58	5,74	15,88	9,91	4,41	7,69
średnia	7,88	3,59	1,65	2,19	1,54	5,92	7,10	2,33	1,03	1,78	3,50

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, Św: dzień świąteczny; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.4.4. Skuteczność prognozowania metodą naiwną

Metoda naiwna zakłada, że wartość analizowanego parametru w dobie $n+1$ będzie równa wartości za poprzedni okres. Badania obejmują budowę modeli dla 7 dób poprzedzających dobę $n+1$ czyli dla dób $n-1$, $n-2$... $n-7$. Każda z godzin doby $n+1$ posiada w takim modelowaniu wartość zapotrzebowania na moc elektryczną w analogicznej godzinie zadanego okresu poprzedzającego tę dobę. Tabela 4.4.4.1

zawiera wartości błędów MAPE prognoz w latach 2009 – 2018 dla wskazanych modeli naiwnych. Największą jakością wyrażoną wartościami błędów MAPE charakteryzuje się model zakładający, że wartości zapotrzebowania w kolejnych godzinach doby $n+1$ będą posiadały wartości dla 7 wcześniejszych dób. Uzyskane wyniki potwierdzają intuicyjne uproszczone założenie, że zapotrzebowanie na moc elektryczną w kolejnych dniach tygodnia będzie zbliżone do wielkości zapotrzebowania w analogicznych dniach tygodnia minionego siedmiodniowego okresu poprzedzającego (czyli w poniedziałek analizowane wartości będą zbliżone do zapotrzebowania odnotowanego w poprzedni poniedziałek). Uzyskana średnia skuteczność prognozowania dla najkorzystniejszego siedmiodniowego opóźnienia w przypisywaniu wartości dla doby $n+1$ za okres 2009 – 2018 wynosi 4,17%. Wskazana wartość wynika z arytmetycznego uśrednienia dla wartości opisujących analizowany parametr w poszczególnych latach. Zakres zmienności błędów MAPE w poszczególnych latach zmieniał się w zakresie od 3,77% do 4,52%. Wskazane wartości opisują najmniejszą i największą wartość błędu MAPE. Metoda naiwna w obu przypadkach daje korzystniejsze wyniki niż metoda najmniejszych kwadratów (podobnie jak w [53], [54], [55]) pomimo zastosowania tej drugiej dla całego analizowanego szeregu czasowego zamiast wyłącznie dla zapotrzebowania szczytowego w KSE.

Tab. 4.4.4.1. Skuteczność prognozowania w latach kalendarzowych w horyzoncie $n+1$ dla modeli naiwnych w latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].

Model	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
1 doba	7,14	7,08	7,06	7,06	6,95	6,99	7,13	7,22	7,19	7,43	7,13
2 doby	11,11	11,18	10,97	10,81	10,60	10,96	11,16	11,26	11,19	11,37	11,06
3 doby	12,01	12,19	12,11	11,57	11,45	11,85	11,92	12,26	12,04	12,10	11,95
4 doby	12,15	12,35	12,28	11,74	11,62	11,96	12,00	12,42	12,16	12,24	12,09
5 dób	11,67	11,70	11,50	11,57	11,33	11,38	11,47	11,74	11,86	12,03	11,62
6 dób	8,70	8,61	8,46	8,82	8,68	8,54	8,46	8,76	8,77	9,10	8,69
7 dób	4,15	4,13	3,84	4,46	4,37	4,11	3,77	4,23	4,11	4,52	4,17
średnia	9,56	9,61	9,46	9,43	9,28	9,40	9,42	9,70	9,62	9,83	–

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Skuteczność prognozowania uśredniona dla pierwszych 6 godzin każdej doby za lata analizy od 2009 – 2018 dla najskuteczniejszej metody naiwnej (z opóźnieniem siedmiu dób) przedstawiona jest w Tabeli 4.4.4.1. Średnia jakość dla tego modelu we wskazanym okresie wynosi 3,80% i wynika z arytmetycznego uśrednienia zakresu zmienności od 3,23% (2015) do 4,15% (2009). Zauważalny był rosnący trend efektywności w latach 2010 – 2011 oraz w latach 2013 – 2017. Największa efektywność dotyczy pierwszej godziny analizy (3,59%) i maleje sukcesywnie do ostatniej godziny analizy (4,11%).

4.4.5. Skuteczność prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej na tle metody naiwnej z opóźnieniem siedmiu dób

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej testowanej na danych historycznych KSE dla godzin 00:00 – 05:00 (Tab. 4.4.5.1) w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-7) wskazuje, że opracowana metoda różni się skutecznością w najkorzystniejszym przypadku o 1,66% dla godziny 02:00.

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.4.5.1. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
00:00	1,98	1,90	1,95	1,62	1,70	2,20	2,50	2,03	1,93	1,76	1,96
01:00	1,76	1,61	1,72	1,34	1,43	1,93	2,26	1,90	1,74	1,51	1,72
02:00	1,86	1,54	1,72	1,22	1,30	1,83	2,21	1,85	1,64	1,45	1,66
03:00	1,92	1,60	1,82	1,24	1,40	1,99	2,37	1,98	1,84	1,62	1,78
04:00	2,10	1,61	1,99	1,32	1,61	2,13	2,52	2,06	2,12	1,92	1,94
05:00	2,79	2,31	2,78	2,26	2,50	2,98	3,47	2,95	2,94	2,96	2,80
<i>średnia</i>	2,07	1,76	2,00	1,50	1,66	2,18	2,55	2,13	2,03	1,87	1,98

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej testowanej na danych historycznych KSE dla godzin 06:00 – 23:00 (Tab. 4.4.5.2) w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-7) wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 2,18% dla godziny 23:00.

Tab. 4.4.5.2. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
06:00	5,34	5,19	5,61	5,33	5,56	6,02	6,64	5,79	5,82	5,86	5,71
07:00	7,69	6,98	7,25	7,02	7,23	7,71	8,35	7,39	7,37	7,42	7,44
08:00	7,94	6,91	6,91	6,77	6,96	7,38	8,08	7,14	7,23	7,44	7,27
09:00	6,98	6,03	5,85	5,84	5,97	6,27	6,96	6,19	6,21	6,34	6,26
10:00	6,08	5,18	5,04	4,86	5,10	5,28	5,84	5,34	5,35	5,55	5,36
11:00	6,11	5,19	5,08	4,87	5,09	5,24	5,74	5,46	5,35	5,63	5,37
12:00	6,09	5,11	5,09	4,87	5,13	5,18	5,70	5,47	5,30	5,60	5,35
13:00	6,01	5,02	5,12	4,84	5,10	5,09	5,61	5,34	5,22	5,59	5,29
14:00	6,01	5,01	5,20	4,88	5,12	5,19	5,55	5,42	5,34	5,60	5,33
15:00	6,03	5,09	5,32	5,01	5,30	5,36	5,72	5,51	5,42	5,78	5,45
16:00	5,45	4,80	5,05	4,75	4,96	4,99	5,31	5,08	4,98	5,40	5,08
17:00	4,89	4,27	4,49	4,07	4,42	4,28	4,77	4,54	4,35	4,78	4,48
18:00	4,01	3,62	3,74	3,30	3,74	3,73	4,23	3,86	3,77	4,07	3,81
19:00	3,52	3,36	3,42	3,08	3,25	3,60	3,99	3,71	3,57	3,74	3,52
20:00	3,60	3,38	3,47	3,12	3,38	3,77	4,04	3,65	3,50	3,66	3,56
21:00	3,34	2,95	3,14	2,78	3,08	3,38	3,70	3,37	3,14	3,13	3,20
22:00	2,46	2,29	2,31	2,04	2,28	2,53	2,80	2,55	2,33	2,21	2,38
23:00	2,35	2,12	2,10	1,88	1,99	2,35	2,69	2,24	2,13	1,95	2,18
<i>średnia</i>	5,22	4,58	4,68	4,41	4,65	4,85	5,32	4,89	4,80	4,99	4,84

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Dni tygodnia, dni świąteczne i dni niestandardowe

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.4.5.3) w podziale na typy dni daje poprawę skuteczności w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-7).

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.4.5.3. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
00:00	0,03	8,46	-0,44	-0,45	-0,41	-0,89	7,41	1,36	3,44	-0,19	-1,74
01:00	-1,02	7,91	-0,64	-0,52	-0,44	-0,73	7,49	1,00	3,53	-1,00	-2,66
02:00	-1,50	7,58	-0,80	-0,52	-0,46	-0,45	7,79	0,84	3,72	-1,35	-3,40
03:00	-1,51	7,59	-0,89	-0,57	-0,43	0,01	8,25	0,82	4,17	-1,53	-3,30
04:00	-0,49	7,14	-1,14	-0,63	-0,53	0,84	8,38	0,87	4,61	-1,90	-3,51
05:00	3,95	5,73	-1,20	-0,42	-0,80	3,50	8,81	1,39	6,32	-2,84	-3,50
średnia	-0,09	7,40	-0,85	-0,52	-0,51	0,38	8,02	1,05	4,30	-1,47	-3,02

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Największa poprawa skuteczności, na poziomie 3,02%, uzyskiwana jest dla Wigilii świąt Bożego Narodzenia i w dalszej kolejności ogółem dla dni świątecznych (1,47%), dla śród (0,85%), dla czwartków (0,52%), dla piątków (0,51%) i dla poniedziałków (0,09%). Największa regresja jakości prognoz otrzymywana jest dla niedziel (8,02%).

Tab. 4.4.5.4. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
06:00	15,48	2,47	-0,70	0,39	-0,82	10,87	12,30	3,24	11,90	-4,35	-3,57
07:00	21,80	0,80	-0,08	1,03	-0,39	14,31	14,60	4,45	14,90	-4,28	-1,67
08:00	22,33	-0,24	0,11	1,11	-0,19	12,43	15,34	4,49	14,24	-2,74	-0,61
09:00	19,93	-0,76	0,04	0,80	-0,41	9,68	14,54	3,86	12,28	-1,47	-0,63
10:00	17,47	-0,82	0,04	0,42	-0,59	7,89	13,10	3,29	10,55	-0,98	-0,83
11:00	17,62	-0,82	0,06	0,48	-0,65	8,30	12,62	3,32	10,51	-1,34	-1,03
12:00	17,72	-0,77	0,12	0,39	-0,66	9,13	11,53	3,35	10,36	-1,96	-1,78
13:00	17,63	-0,80	0,28	0,26	-0,68	9,72	10,62	3,30	10,27	-2,36	-2,20
14:00	17,78	-0,75	0,47	0,23	-0,65	10,78	9,44	3,35	10,29	-2,83	-2,38
15:00	18,04	-0,78	0,43	0,14	-0,64	11,26	9,69	3,40	10,57	-2,88	-2,01
16:00	16,61	-0,72	0,20	-0,05	-0,89	10,78	9,59	3,04	10,18	-3,08	-1,78
17:00	15,04	-0,78	-0,06	-0,30	-0,97	10,20	8,25	2,64	9,09	-4,12	-1,68
18:00	13,27	-0,81	-0,26	-0,36	-1,09	9,23	6,66	2,21	7,78	-5,19	-1,31
19:00	12,50	-0,68	-0,25	-0,27	-0,83	9,33	4,86	2,14	6,97	-5,69	-1,50
20:00	12,56	-0,48	-0,18	-0,05	-0,37	9,43	3,99	2,33	6,63	-5,18	-1,82
21:00	11,79	-0,57	0,03	-0,10	-0,01	8,87	2,38	2,24	5,60	-4,68	-1,81
22:00	9,29	-0,51	-0,04	-0,41	-0,48	7,38	1,42	1,57	4,41	-4,21	-1,52
23:00	8,52	-0,54	-0,29	-0,45	-0,77	7,32	1,45	1,31	4,36	-4,33	-2,37
średnia	15,85	-0,42	0,00	0,18	-0,62	9,83	9,02	2,97	9,49	-3,43	-1,69

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.4.5.4) w podziale na typy dni daje poprawę jakości w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-7). Największa poprawa skuteczności, na poziomie 3,43%, uzyskiwana jest dla wszystkich dni świątecznych i niestandardowych i w dalszej kolejności ogółem dla Wigilii Świąt Bożego Narodzenia (1,69%), dla piątków (0,62%) i dla wtorków (0,42%). Największa regresja jakości prognoz otrzymywana jest dla poniedziałków (15,85%).

Dni świąteczne i dni niestandardowe

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.4.5.5 i Tab. 4.4.5.6) dla dni świątecznych daje poprawę efektywności w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-7). Największą poprawę efektywności, średnio dla tych godzin, na poziomie 15,19%, uzyskuje się dla drugiego dnia Świąt Bożego Narodzenia. W dalszej kolejności poprawa skuteczności dotyczy drugiego dnia Świąt Wielkiej Nocy (12,66%), Święta 3. Maja (8,99%), pierwszego dnia Świąt Bożego Narodzenia (5,95%), dnia 2. Maja (3,82%), Wigilii Bożego Narodzenia (3,02%), Święta Wniebowzięcia NMP (0,48%), Święta Bożego Ciała (0,27%) i Święta Nowego Roku (0,14%). Największą regresją efektywności prognoz charakteryzują się Zielone Świątki (11,74%).

Tab. 4.4.5.5. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
00:00	-4,45	1,88	9,25	-5,19	4,44	-2,42	-5,42	10,09
01:00	-4,98	1,66	7,60	-7,15	4,48	-3,27	-6,28	10,32
02:00	-3,04	1,74	7,77	-10,25	5,17	-3,58	-7,57	10,86
03:00	-0,02	1,75	8,39	-13,56	5,71	-4,08	-8,64	11,58
04:00	4,13	1,75	8,02	-16,40	7,84	-4,72	-10,91	12,86
05:00	7,52	2,37	7,13	-23,41	12,30	-4,83	-15,15	14,71
<i>średnia</i>	-0,14	1,86	8,03	-12,66	6,66	-3,82	-8,99	11,74

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.4.5.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
00:00	-0,23	-0,46	0,49	5,75	-1,74	-3,86	-8,77	-0,31
01:00	-0,06	-0,73	0,36	6,77	-2,66	-4,91	-12,23	-0,19
02:00	0,30	-1,04	0,55	6,67	-3,40	-5,64	-14,46	-0,06
03:00	0,39	-0,35	0,31	6,93	-3,30	-6,82	-16,11	0,20
04:00	-0,81	0,01	0,35	6,42	-3,51	-6,67	-18,47	-0,12
05:00	-1,20	-0,30	1,40	4,96	-3,50	-7,79	-21,09	0,64
<i>średnia</i>	-0,27	-0,48	0,58	6,25	-3,02	-5,95	-15,19	0,03

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.4.5.7. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
06:00	14,73	4,64	9,51	-43,81	24,12	-2,12	-19,90	19,25
07:00	22,84	5,82	12,99	-55,32	29,37	-0,31	-21,73	21,84
08:00	28,70	5,54	15,92	-53,86	27,08	-0,41	-20,05	21,74
09:00	29,83	4,66	17,01	-46,09	22,95	-0,84	-16,97	20,23
10:00	27,81	3,96	16,89	-40,53	20,02	-1,82	-15,39	18,58
11:00	24,30	3,91	17,35	-41,63	20,34	-1,39	-15,80	18,41
12:00	20,19	3,92	15,97	-42,03	20,66	-1,51	-15,96	17,48
13:00	16,79	3,94	14,16	-40,32	20,24	-1,25	-15,75	16,65
14:00	13,35	4,01	11,20	-39,23	21,05	-1,24	-16,13	15,24
15:00	13,21	4,13	11,11	-40,09	22,28	-1,38	-16,71	15,27
16:00	8,33	3,72	11,23	-38,52	22,61	-1,76	-16,98	15,32
17:00	1,41	3,38	9,66	-37,47	21,57	-2,36	-17,09	14,15
18:00	-2,18	3,08	7,13	-36,24	19,90	-3,26	-16,55	12,17
19:00	-3,11	2,97	3,68	-33,05	19,21	-4,25	-16,74	9,89
20:00	-2,25	2,91	3,37	-29,13	18,61	-4,86	-15,59	8,17
21:00	-0,07	2,55	1,35	-25,63	14,41	-3,88	-11,79	5,47
22:00	1,61	1,97	-0,75	-21,32	11,60	-3,67	-11,46	4,79
23:00	3,05	1,69	-2,85	-20,95	11,49	-4,44	-11,63	5,09
<i>średnia</i>	12,14	3,71	9,72	-38,07	20,42	-2,26	-16,23	14,43

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.4.5.7 i Tab. 4.4.5.8) dla dni świątecznych daje poprawę skuteczności w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-7). Największą poprawę efektywności, średnio dla tych godzin, na poziomie 38,07%, uzyskuje się dla drugiego dnia Świąt Wielkiej Nocy. W dalszej kolejności poprawa jakości dotyczy drugiego dnia Świąt Bożego Narodzenia (23,55%), Święta 3. Maja (16,23%), pierwszego dnia Świąt Bożego Narodzenia (3,49%), dnia 2. Maja (2,26%), Święta Wniebowzięcia NMP (2,19%), Wigilii Świąt Bożego Narodzenia (1,69%), Święta Bożego Ciała (0,57%). Największą regresją jakości prognoz charakteryzuje się Święto 1. Maja (20,42%).

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.4.5.9) dla dni świątecznych i niestandardowych dają poprawę efektywności dla całego okresu analizy. Największa poprawa efektywności dotyczy drugiego dnia Świąt Bożego Narodzenia (15,19%) i w dalszej kolejności dla Poniedziałku Wielkanocnego (12,66%), dla Święta 3. Maja (8,99%), pierwszego dnia Świąt Bożego Narodzenia (5,95%), dla 2. Maja (3,82%), Wigilii Świąt Bożego Narodzenia (3,02%), dla Święta Wniebowzięcia NMP (0,48%) i dla Święta Bożego Ciała (0,27%). Największa regresja skuteczności prognoz otrzymywana jest dla Zielonych Świątków (11,74%).

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.4.5.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
06:00	-1,21	-1,71	-0,48	5,65	-3,57	-9,41	-26,64	5,11
07:00	-0,26	-3,01	-0,20	7,47	-1,67	-9,63	-29,77	9,35
08:00	-0,10	-2,97	1,07	8,04	-0,61	-7,66	-26,56	10,64
09:00	0,05	-2,94	0,99	7,43	-0,63	-4,35	-23,05	8,84
10:00	-0,03	-2,47	0,90	6,61	-0,83	-2,65	-20,71	7,33
11:00	-0,10	-2,11	0,79	6,77	-1,03	-1,98	-21,21	7,38
12:00	0,09	-1,99	0,78	6,52	-1,78	-2,63	-21,57	7,40
13:00	-0,34	-2,03	0,24	6,18	-2,20	-2,77	-20,87	7,20
14:00	-0,14	-1,94	-0,14	5,98	-2,38	-2,70	-20,66	6,92
15:00	-0,36	-2,17	0,69	5,84	-2,01	-2,57	-19,73	7,05
16:00	-0,87	-2,17	3,26	4,70	-1,78	-1,23	-19,90	4,68
17:00	-1,16	-2,36	4,25	4,23	-1,68	-0,60	-25,24	-3,19
18:00	-1,26	-2,60	1,25	3,56	-1,31	-0,61	-28,38	-6,41
19:00	-1,09	-2,26	0,70	3,30	-1,50	-1,48	-29,09	-0,91
20:00	-1,09	-1,24	0,29	3,02	-1,82	-1,86	-26,96	9,19
21:00	-0,84	-1,81	-0,26	2,74	-1,81	-2,10	-24,42	12,74
22:00	-0,42	-1,87	-0,20	2,69	-1,52	-3,27	-20,78	9,03
23:00	-1,08	-1,83	-0,35	2,42	-2,37	-5,22	-18,42	3,43
średnia	-0,57	-2,19	0,75	5,17	-1,69	-3,49	-23,55	5,88

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.4.5.9. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędów MAPE, [%].

Św.	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	6,59	8,56	2,93	-4,04	-0,71	-0,16	-4,05	-9,43	2,40	-3,50	-0,14
S02	0,00	0,00	4,88	0,09	1,51	3,18	2,07	3,77	1,38	1,72	1,86
S03	7,86	6,17	8,66	10,77	3,90	10,47	11,51	11,88	12,55	-3,50	8,03
S04	-18,64	-7,35	-15,89	-10,32	-16,05	-15,09	-9,93	-17,24	-13,56	-2,51	-12,66
S05	9,16	7,82	8,30	-0,77	4,22	12,65	5,78	14,29	4,95	0,16	6,66
S06	1,21	6,54	-7,44	-6,55	-4,79	-3,04	2,68	-7,05	-16,69	-3,03	-3,82
S07	1,08	-8,30	-2,46	-14,56	-11,64	-10,47	3,99	-17,06	-14,99	-15,55	-8,99
S08	4,90	11,74	12,79	12,53	11,16	12,81	10,62	10,19	12,60	18,04	11,74
S09	0,12	0,37	-1,15	1,06	0,49	-3,98	-2,02	0,32	0,55	1,58	-0,27
S10	6,39	8,38	-1,51	0,75	-5,93	-1,68	3,51	-2,29	-10,18	-2,24	-0,48
S11	13,74	-0,67	-15,37	4,25	-1,43	6,25	14,88	-12,71	-0,83	-2,35	0,58
S12	-2,87	7,64	6,25	12,43	5,60	-7,74	2,56	9,78	10,86	17,98	6,25
S13	-3,17	-3,19	7,58	-2,09	-11,21	-1,83	-9,55	0,61	8,19	-15,53	-3,02
S14	-4,63	-6,37	9,87	-10,03	-6,98	-7,97	-8,84	5,37	-12,26	-17,64	-5,95
S15	-11,39	-7,95	-14,34	-5,80	-18,98	-15,76	-14,04	-22,17	-24,20	-17,25	-15,19
S16	2,29	-0,10	0,06	-5,62	4,01	-6,07	-4,35	4,95	6,60	-1,51	0,03
średnia	0,79	1,46	0,20	-1,12	-2,93	-1,78	0,30	-1,67	-2,04	-2,82	-0,96

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, Św: dzień świąteczny; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.4.5.10) dla dni świątecznych i niestandardowych dają poprawę efektywności dla całego okresu analizy. Największa poprawa efektywności dotyczy drugiego Świąt Wielkiej Nocy (38,07%) i w dalszej kolejności dla drugiego dnia Świąt Bożego Narodzenia (23,55%), dla Święta 3. Maja (16,23%), pierwszego dnia Świąt Bożego Narodzenia (3,49%), dla 2. Maja (2,26%), Święta Wniebowzięcia NMP (2,19%)

i dla Święta Bożego Ciała (0,57%). Największą regresję skuteczności prognoz charakteryzuje się dla Święto 1. Maja (20,42%).

Tab. 4.4.5.10. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędów MAPE, [%].

Św.	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	16,66	14,99	20,37	8,55	16,70	15,94	12,41	6,07	9,52	0,21	12,14
S02	0,00	0,00	5,42	4,26	3,77	4,46	-0,32	7,30	7,61	4,62	3,71
S03	8,23	14,34	11,28	11,08	7,65	12,61	13,44	8,38	9,96	0,21	9,72
S04	-42,56	-40,79	-39,99	-38,57	-40,41	-45,00	-40,71	-42,88	-37,83	-11,95	-38,07
S05	30,20	22,78	9,54	23,47	23,26	29,03	24,68	16,21	-1,91	26,91	20,42
S06	11,84	10,41	-5,66	-6,79	-5,11	-4,05	12,71	-13,31	-16,13	-6,55	-2,26
S07	-7,23	-30,19	-19,31	-19,24	-23,19	-7,58	-4,89	-7,97	-16,72	-26,03	-16,23
S08	14,88	10,97	11,27	12,52	20,65	13,81	14,70	15,06	12,09	18,34	14,43
S09	-1,12	-0,37	-2,04	0,49	1,83	-5,08	-0,10	0,22	-2,07	2,57	-0,57
S10	15,02	14,59	-25,78	-0,61	-6,95	2,76	11,84	-29,38	-3,06	-0,37	-2,19
S11	15,35	-32,78	-4,85	1,81	3,23	18,01	14,31	-2,90	0,51	-5,14	0,75
S12	1,00	-0,29	6,43	20,06	-20,45	0,07	1,74	4,36	18,43	20,38	5,17
S13	-1,20	-0,62	16,54	-17,65	-2,38	-0,94	-4,93	13,31	7,51	-26,58	-1,69
S14	-2,97	7,04	10,98	1,27	-8,37	-3,48	-4,28	5,27	-36,85	-3,47	-3,49
S15	-12,17	-8,82	-39,48	-19,29	-28,20	-20,86	-13,69	-48,08	-15,94	-29,02	-23,55
S16	8,91	4,78	11,64	0,82	3,01	0,81	0,93	15,02	9,01	3,84	5,88
<i>średnia</i>	<i>3,43</i>	<i>-0,87</i>	<i>-2,10</i>	<i>-1,11</i>	<i>-3,43</i>	<i>0,66</i>	<i>2,37</i>	<i>-3,33</i>	<i>-3,49</i>	<i>-2,00</i>	<i>-0,99</i>

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, Św: dzień świąteczny; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.4.6. Skuteczność prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej na tle metody naiwnej z opóźnieniem jednej doby

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej testowanej na danych historycznych KSE dla godzin 00:00 – 05:00 (Tab. 4.4.6.1) w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-1) wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 0,75% dla godziny 04:00.

Tab. 4.4.6.1. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w poszczególnych latach 2009 – 2018, wyrażona wartościami błędów MAPE, [%].

h	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
00:00	0,82	0,92	0,85	0,95	1,04	1,14	1,01	1,07	0,92	1,07	0,98
01:00	0,83	0,95	0,89	0,94	1,12	1,17	1,05	1,17	0,89	1,07	1,01
02:00	0,76	0,98	0,90	0,96	1,09	1,14	1,00	1,15	0,76	1,00	0,97
03:00	0,61	0,89	0,80	0,80	1,05	1,06	0,94	1,09	0,74	0,98	0,90
04:00	0,64	0,66	0,64	0,63	0,88	0,92	0,77	0,83	0,68	0,88	0,75
05:00	0,71	0,56	0,62	0,81	1,04	0,99	0,80	0,80	0,67	1,06	0,81
<i>średnia</i>	<i>0,73</i>	<i>0,83</i>	<i>0,78</i>	<i>0,85</i>	<i>1,04</i>	<i>1,07</i>	<i>0,93</i>	<i>1,02</i>	<i>0,78</i>	<i>1,01</i>	<i>0,90</i>

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.4.6.2. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2009 – 2018
06:00	1,22	1,01	0,91	1,26	1,55	1,53	1,38	1,02	1,00	1,42	1,23
07:00	1,56	1,09	0,99	1,45	1,85	1,95	1,77	1,34	1,35	1,80	1,51
08:00	1,57	1,05	0,90	1,40	1,77	1,91	1,79	1,40	1,48	2,04	1,53
09:00	1,44	1,02	0,79	1,36	1,61	1,68	1,61	1,31	1,34	1,68	1,38
10:00	1,31	1,01	0,77	1,25	1,50	1,50	1,55	1,38	1,27	1,55	1,31
11:00	1,37	1,02	0,79	1,28	1,55	1,55	1,60	1,51	1,32	1,61	1,36
12:00	1,38	1,00	0,81	1,30	1,55	1,54	1,59	1,58	1,30	1,55	1,36
13:00	1,27	0,95	0,78	1,22	1,49	1,42	1,53	1,47	1,22	1,44	1,28
14:00	1,25	0,92	0,76	1,20	1,48	1,45	1,49	1,47	1,27	1,41	1,27
15:00	1,18	0,91	0,68	1,21	1,47	1,42	1,46	1,39	1,18	1,41	1,23
16:00	1,05	0,93	0,64	1,09	1,35	1,28	1,29	1,21	1,05	1,27	1,12
17:00	1,07	0,90	0,67	1,04	1,31	1,13	1,29	1,16	0,97	1,20	1,07
18:00	1,02	0,93	0,70	0,95	1,24	1,10	1,20	1,12	0,92	1,18	1,03
19:00	0,98	0,97	0,74	0,98	1,25	1,12	1,12	1,08	0,86	1,22	1,03
20:00	0,84	0,93	0,77	0,96	1,20	1,08	1,01	1,01	0,76	1,15	0,97
21:00	0,86	0,89	0,80	0,95	1,17	1,12	1,04	1,14	0,89	1,17	1,00
22:00	0,82	0,90	0,82	0,93	1,08	1,07	0,98	1,17	0,89	1,07	0,97
23:00	0,86	0,90	0,80	0,91	1,02	1,01	0,97	1,05	0,90	1,05	0,95
<i>średnia</i>	<i>1,17</i>	<i>0,96</i>	<i>0,79</i>	<i>1,15</i>	<i>1,41</i>	<i>1,38</i>	<i>1,37</i>	<i>1,27</i>	<i>1,11</i>	<i>1,40</i>	<i>1,20</i>

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej testowanej na danych historycznych KSE dla godzin 06:00 – 23:00 (Tab. 4.4.6.2) w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-1) wskazuje, że różni się ona jakością w najkorzystniejszym przypadku o 0,95% dla godziny 23:00.

Dni tygodnia, dni świąteczne i dni niestandardowe

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.4.6.3) w podziale na typy dni daje poprawę skuteczności w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-1). Największą poprawę jakości, na poziomie 8,46%, uzyskuje się dla czwartków i w dalszej kolejności dla sobót (5,49%) i śród (0,51%). Największa regresja skuteczności otrzymywana jest dla niedziel (9,59%).

Tab. 4.4.6.3. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
00:00	2,19	8,99	1,37	-7,73	1,27	-8,06	8,83	1,09	0,71	3,50	1,32
01:00	1,27	9,66	1,01	-7,96	1,37	-7,30	9,02	1,16	0,63	3,65	1,93
02:00	0,83	9,52	0,57	-8,21	1,39	-6,56	9,29	1,14	0,56	3,69	2,47
03:00	0,92	8,89	-0,10	-8,73	1,47	-5,98	9,81	1,06	0,49	3,93	3,10
04:00	2,05	6,71	-1,37	-9,04	1,53	-4,63	10,03	0,94	0,28	4,07	3,25
05:00	6,87	0,72	-4,51	-9,10	1,54	-0,42	10,56	1,00	0,32	3,90	4,43
<i>średnia</i>	<i>2,35</i>	<i>7,42</i>	<i>-0,51</i>	<i>-8,46</i>	<i>1,43</i>	<i>-5,49</i>	<i>9,59</i>	<i>1,06</i>	<i>0,50</i>	<i>3,79</i>	<i>2,75</i>

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.4.6.4) w podziale na typy dni daje poprawę skuteczności w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-1). Największą poprawę jakości, na poziomie 14,61%, uzyskuje się dla wtorków i w dalszej kolejności dla śród (9,40%) i czwartków (8,27%). Największa regresja jakości otrzymywana jest dla poniedziałków (17,69%).

Tab. 4.4.6.4. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

<i>h</i>	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	rob.	wee.	Św.	Wig.
06:00	18,45	-12,45	-11,31	-11,53	1,74	9,60	14,13	1,47	0,63	5,98	7,37
07:00	24,58	-18,96	-13,85	-14,09	2,21	14,36	16,38	1,94	0,46	7,13	9,18
08:00	24,71	-20,01	-11,46	-14,95	2,25	13,16	17,03	1,98	0,42	7,37	7,55
09:00	21,96	-18,30	-8,60	-13,99	1,90	10,58	16,16	1,71	0,56	7,27	5,21
10:00	19,36	-16,12	-6,88	-12,38	1,65	8,90	14,67	1,56	0,69	7,09	3,77
11:00	19,50	-16,06	-7,14	-11,93	1,66	9,34	14,18	1,63	0,70	6,92	3,28
12:00	19,56	-15,99	-8,06	-10,89	1,66	10,17	13,09	1,65	0,63	6,76	2,61
13:00	19,39	-16,05	-8,89	-10,03	1,61	10,77	12,18	1,58	0,54	6,58	2,00
14:00	19,50	-16,05	-10,08	-8,89	1,62	11,81	10,98	1,60	0,45	6,63	1,66
15:00	19,72	-16,52	-10,67	-8,95	1,58	12,27	11,21	1,53	0,48	6,73	1,78
16:00	18,32	-15,98	-10,51	-8,45	1,45	11,82	11,18	1,31	0,62	6,12	1,13
17:00	16,83	-14,82	-10,12	-7,02	1,36	11,38	9,92	1,23	0,69	5,76	0,86
18:00	15,17	-13,30	-9,35	-5,46	1,28	10,53	8,40	1,17	0,69	5,82	0,93
19:00	14,12	-12,40	-9,46	-3,62	1,41	10,62	6,57	1,17	0,69	6,22	1,32
20:00	13,62	-12,25	-9,46	-2,92	1,75	10,58	5,48	1,14	0,56	6,12	1,57
21:00	12,66	-10,89	-8,62	-1,85	1,98	9,97	3,77	1,24	0,40	5,38	1,27
22:00	10,73	-8,62	-7,27	-1,03	1,53	8,52	2,94	1,17	0,49	4,45	2,21
23:00	10,28	-8,13	-7,46	-0,91	1,31	8,55	2,99	1,11	0,55	4,02	3,50
średnia	17,69	-14,61	-9,40	-8,27	1,66	10,72	10,63	1,45	0,57	6,24	3,18

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Dni świąteczne i dni niestandardowe

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.4.6.5 i Tab. 4.4.6.6) dla dni świątecznych daje poprawę skuteczności w porównaniu do prognoz uzyskanych dla modelu naiwnego MN(-1). Największą poprawę jakości, średnio dla tych godzin, na poziomie 0,15%, uzyskuje się dla Zielonych Świątków, a następnie dla Sylwestra (0,05%). Poprawa jakości prognozowania dla pierwszego przykładu uzyskiwana jest dla pierwszych 4 godzin doby na poziomie od 0,34% do 0,61%. W drugim przykładzie poprawa efektywności prognoz odnotowywana jest dla godzin od 03:00 do 05:00 na poziomie od 0,03% do 1,03%. Dla Bożego Ciała oraz dla Święta Wniebowzięcia NMP odnotowywana jest poprawa efektywności w niektórych godzinach doby, jednakże średnia efektywność prognoz w omawianych godzinach doby dla tych dni nie jest odnotowywana. Największa regresja jakości prognoz odnotowywana jest dla drugiego dnia Świąt Bożego Narodzenia (15,34%).

Tab. 4.4.6.5. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
00:00	-0,18	0,83	6,23	4,50	1,78	4,79	3,20	-0,50
01:00	0,19	0,79	6,65	4,60	1,44	5,17	3,43	-0,34
02:00	0,18	0,79	6,92	4,60	1,84	5,97	2,66	-0,61
03:00	0,51	0,58	7,22	4,14	1,99	6,24	3,12	-0,44
04:00	1,24	0,31	7,32	3,53	3,23	7,91	3,52	0,35
05:00	0,96	0,19	7,71	1,68	3,17	10,48	2,23	0,62
<i>średnia</i>	0,48	0,58	7,01	3,84	2,24	6,76	3,03	-0,15

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.4.6.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
00:00	0,45	-0,33	1,17	3,95	1,32	5,90	16,08	0,75
01:00	0,56	-0,24	1,29	4,49	1,93	8,30	14,35	0,42
02:00	0,69	-0,04	1,01	4,33	2,47	9,45	14,98	0,28
03:00	1,01	0,70	0,90	4,61	3,10	10,30	15,55	-0,03
04:00	-0,11	0,83	1,20	4,51	3,25	11,79	14,90	-0,71
05:00	-0,88	0,99	2,16	3,48	4,43	13,52	16,15	-1,03
<i>średnia</i>	0,29	0,32	1,29	4,23	2,75	9,88	15,34	-0,05

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Zastosowanie metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.4.6.7 i Tab. 4.4.6.8) dla dni świątecznych wskazuje, że największą liczbą godzin z analizowanego zakresu, dla których otrzymywana jest poprawa skuteczności prognozowania charakteryzuje się Święto Bożego Ciała (11 godzin), a poprawa jakości kształtuje się na poziomie od 0,07% do 0,83%. Dla Święta 3. Maja poprawa efektywności zachodzi dla 6 godzin i kształtuje się na poziomie od 0,61% do 1,15%. Dla Nowego Roku i Sylwestra poprawa jakości występuje dla 5 godzin i osiąga poziom odpowiednio od 0,81% do 6,23% oraz od 0,26% do 0,78%. W drugi dzień Świąt Wielkiej Nocy poprawa efektywności prognoz na poziomie 1,25% odnotowywana jest tylko dla godziny 08:00.

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 (Tab. 4.4.6.9) dla dni świątecznych i niestandardowych dają poprawę skuteczności dla całego okresu analizy. Największą poprawę jakości (0,15%) uzyskuje się dla Zielonych Świątków, a następnie dla Sylwestra (0,05%). Największa regresja efektywności zachodzi dla drugiego dnia Świąt Bożego narodzenia (15,34%).

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.4.6.7. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	S01	S02	S03	S04	S05	S06	S07	S08
06:00	1,22	0,59	8,77	2,18	4,66	12,81	2,01	0,90
07:00	1,36	0,82	8,53	0,03	4,99	12,76	1,99	0,63
08:00	2,32	0,86	8,86	-1,25	4,54	10,56	1,46	0,33
09:00	2,17	0,69	9,63	3,99	3,82	8,42	1,58	0,41
10:00	1,96	0,76	11,23	6,50	3,48	6,57	1,39	0,67
11:00	1,03	0,66	11,93	4,61	3,33	7,14	1,36	0,34
12:00	0,19	0,65	11,61	4,78	3,49	6,40	1,10	0,40
13:00	0,01	0,72	10,06	6,66	3,28	5,12	0,25	0,48
14:00	0,06	0,65	7,62	9,37	3,75	3,70	-0,74	0,33
15:00	0,70	0,67	7,83	9,58	4,14	3,80	-0,65	0,76
16:00	-1,13	0,55	9,44	10,73	3,94	3,22	-0,88	1,48
17:00	-5,20	0,47	10,11	9,19	4,36	2,88	-1,12	1,98
18:00	-6,23	0,59	10,85	7,25	4,62	2,56	-1,15	2,40
19:00	-2,42	0,61	11,35	6,61	5,35	3,02	-0,61	2,60
20:00	1,69	0,47	10,48	3,10	5,81	4,58	1,43	2,34
21:00	2,24	0,65	7,59	2,32	4,24	4,10	1,79	1,25
22:00	1,53	0,64	5,87	1,87	3,80	4,28	0,87	1,18
23:00	-0,81	0,56	4,98	1,68	4,11	3,57	0,75	1,63
średnia	0,04	0,65	9,26	4,96	4,21	5,86	0,60	1,12

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Tab. 4.4.6.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędów MAPE, [%].

<i>h</i>	S09	S10	S11	S12	S13	S14	S15	S16
06:00	-0,40	2,84	5,38	4,43	7,37	21,90	24,13	-0,19
07:00	0,09	3,00	5,53	6,65	9,18	28,03	31,92	1,35
08:00	0,30	2,99	5,03	6,82	7,55	27,29	36,71	2,45
09:00	-0,07	3,04	4,71	5,69	5,21	24,73	34,51	1,95
10:00	-0,66	3,28	5,27	4,52	3,77	22,89	31,21	1,57
11:00	-0,48	3,64	5,74	4,64	3,28	24,22	29,08	1,98
12:00	-0,38	3,85	5,82	4,49	2,61	24,83	27,27	1,94
13:00	-0,66	3,58	5,52	4,20	2,00	24,96	26,57	1,50
14:00	-0,12	3,75	5,88	4,08	1,66	25,19	26,36	1,26
15:00	-0,43	3,69	5,80	3,41	1,78	24,27	27,80	1,41
16:00	-0,83	3,94	1,55	2,60	1,13	25,51	23,25	0,03
17:00	-0,61	3,50	0,43	4,05	0,86	33,89	14,10	-0,78
18:00	-0,30	3,35	4,17	4,18	0,93	38,71	7,63	-0,76
19:00	0,57	3,33	5,20	4,52	1,32	39,01	5,33	-0,73
20:00	1,78	2,38	5,72	4,31	1,57	35,40	5,23	-0,26
21:00	2,34	3,17	5,73	4,12	1,27	29,80	4,77	0,29
22:00	1,79	2,90	7,38	3,22	2,21	21,98	4,68	0,15
23:00	1,50	2,90	8,68	2,99	3,50	17,22	6,30	0,14
średnia	0,19	3,29	5,20	4,38	3,18	27,21	20,38	0,74

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

Tab. 4.4.6.9. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędów MAPE, [%].

Św.	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2013 – 2018
S01	6,59	4,52	-1,23	-2,01	-0,62	1,15	-1,34	-3,01	0,88	-0,10	0,48
S02	0,00	0,00	1,57	-0,76	0,96	1,27	1,31	1,42	0,33	-0,26	0,58
S03	8,18	2,47	8,07	8,28	8,13	7,54	7,34	11,71	8,45	-0,10	7,01
S04	6,22	8,94	6,53	4,57	2,39	5,35	3,89	-1,81	4,44	-2,13	3,84
S05	0,86	4,81	-1,74	0,27	2,55	8,46	1,40	3,11	1,99	0,70	2,24
S06	15,05	4,48	-1,58	11,03	6,10	8,11	8,46	0,18	4,16	11,63	6,76
S07	8,85	2,13	0,20	1,73	4,19	4,88	7,33	0,36	1,94	-1,35	3,03
S08	0,98	-0,57	-0,47	-0,57	-1,82	0,04	0,01	-2,39	0,17	3,08	-0,15
S09	1,01	0,66	-0,08	0,72	-0,48	-0,05	-0,06	1,14	-0,18	0,19	0,29
S10	4,77	-2,50	1,92	-0,77	1,40	-1,72	3,22	-2,02	0,31	-1,45	0,32
S11	3,56	2,51	2,38	0,36	-1,12	2,23	4,54	0,32	-2,28	0,38	1,29
S12	-2,16	4,82	4,49	3,16	5,56	3,29	5,24	6,94	6,84	4,10	4,23
S13	2,97	5,33	4,17	-1,38	2,00	6,10	1,50	3,77	5,36	-2,36	2,75
S14	12,13	11,91	8,08	4,84	11,78	10,14	11,78	11,77	6,52	9,82	9,88
S15	19,73	13,66	4,19	23,86	18,46	16,55	19,62	5,18	13,07	19,05	15,34
S16	-0,33	0,71	-0,14	0,04	1,53	-2,06	-0,31	1,66	-0,70	-0,93	-0,05
średnia	5,53	3,99	2,27	3,34	3,81	4,46	4,62	2,40	3,21	2,52	3,61

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, Św: dzień świąteczny; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

Wyniki metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 06:00 – 23:00 (Tab. 4.4.6.10) dla dni świątecznych i niestandardowych wskazuje, że opracowana metoda różni się jakością w najkorzystniejszym przypadku o 0,04% dla Nowego Roku.

Tab. 4.4.6.10. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędów MAPE, [%].

Św.	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2013-2018
S01	16,66	-1,68	-0,04	-4,14	2,46	-0,62	-3,73	-2,28	-1,31	-4,94	0,04
S02	0,00	0,00	0,45	-0,30	1,13	1,63	1,26	1,47	0,00	0,81	0,65
S03	8,87	12,28	12,29	9,84	11,81	12,46	10,77	10,34	8,91	-4,94	9,26
S04	7,50	4,87	9,70	8,73	7,22	9,21	3,31	7,20	3,39	-11,58	4,96
S05	6,19	4,03	-4,03	9,18	4,49	6,91	4,27	2,36	-2,25	10,91	4,21
S06	23,47	10,37	1,30	-0,55	3,13	9,80	22,61	-4,38	-6,60	-0,54	5,86
S07	-6,98	1,95	-3,71	-0,81	-3,16	2,28	-5,60	16,34	11,02	-5,31	0,60
S08	1,23	-1,20	0,78	-0,68	7,24	-0,54	0,62	1,51	-0,31	2,52	1,12
S09	0,73	0,40	0,23	0,55	1,56	-0,97	-0,40	1,15	-0,91	-0,44	0,19
S10	2,98	-0,89	3,59	-1,07	4,03	5,20	4,63	0,49	9,69	4,21	3,29
S11	4,65	2,95	13,02	2,29	4,98	1,79	5,65	12,46	2,76	1,41	5,20
S12	3,82	-0,59	2,30	5,39	2,62	14,20	5,11	1,83	3,56	5,61	4,38
S13	1,97	4,39	3,10	-1,56	7,34	4,53	4,42	5,44	1,60	0,54	3,18
S14	31,32	29,61	13,77	34,00	30,84	32,27	34,77	16,56	11,32	37,67	27,21
S15	28,71	7,63	6,33	30,63	22,25	18,06	23,59	5,43	39,18	21,98	20,38
S16	2,32	0,52	1,73	-0,83	1,49	0,02	-1,23	2,36	0,58	0,41	0,74
średnia	8,34	4,66	3,80	5,67	6,84	7,26	6,88	4,89	5,04	3,65	5,70

Legenda: „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu, Św: dzień świąteczny; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256].

4.5. Podsumowanie dla trzech obszarów walidacji opracowanego modelu

W rozdziale czwartym zaprezentowano skuteczność prognoz zapotrzebowania na moc elektryczną opracowywanych przez polskiego Operatora Systemu Przesyłowego oraz jakość prognoz z wykorzystaniem metody ważonych współczynników funkcji autokorelacji cząstkowej bazującej na danych historycznych. Porównanie skuteczności prognoz obu typów stanowi pierwszy obszar walidacyjny dla opracowanej metody ważonych współczynników funkcji autokorelacji cząstkowej. Drugim obszarem walidacyjnym jest porównanie jakości prognoz metody ważonych współczynników funkcji autokorelacji cząstkowej bazującej na danych historycznych zagranicznych systemów elektroenergetycznych z jakością prognoz opracowywanych przez operatorów zagranicznych przesyłowych systemów elektroenergetycznych. Do zagranicznych systemów elektroenergetycznych zakwalifikowano systemy Szwecji i Francji. Trzecim obszarem walidacyjnym jest porównanie skuteczności prognoz metody ważonych współczynników funkcji autokorelacji cząstkowej z dwoma najskuteczniejszymi autoregresyjnymi modelami z grupy 80 modeli autoregresyjnych. Dwoma najskuteczniejszymi modelami są model ARIMA i modele naiwne z opóźnieniem 7 dób. Do grupy weryfikacyjnej w trzecim obszarze walidacyjnym dołączono model naiwny z opóźnieniem 1 doby, który plasuje się na szóstym miejscu pod względem jakości. Wybór podyktowany był przynależnością do grupy modeli naiwnych oraz niewielką różnicą (2,13%) w osiągniętej skuteczności w porównaniu do modelu średniej kroczącej dwuokresowej, której jakość uplasowana jest na trzeciej pozycji w rankingu skuteczności zbioru wybranych modeli. W dalszej części rozważań zaprezentowano zestawienia tabelaryczne zawierające podsumowania dotyczące efektywności opracowanej metody ważonych współczynników funkcji autokorelacji cząstkowej na tle modeli w trzech obszarach walidacji. W kolumnie model znajduje się skrót nazwy modelu, w kolumnie „h” cyfra 1 oznacza przedział godzin od 00:00 do 05:00, a cyfra 2 określa przedział godzin od 06:00 do 23:00. Wartości opatrzone znakiem „-” i podświetlone kolorem zielonym oznaczają mniejsze błędy prognozy metodą ważonych współczynników funkcji autokorelacji cząstkowej w porównaniu do poszczególnych modeli, na których weryfikowano model. Podświetleniem w kolorze pomarańczowym zaznaczono błędy prognoz, które w porównaniu metody ważonych współczynników funkcji autokorelacji cząstkowej do innych modeli są nie większe niż 1%.

Dni tygodnia, dni świąteczne i dni niestandardowe

W Tabeli 4.5.1 zamieszczone zostały wyniki porównawcze skuteczności prognoz metodą ważonych współczynników funkcji autokorelacji cząstkowej za cały okres analizy dla poszczególnych typów dni. W przypadku modeli dla zagranicznych systemów elektroenergetycznych okres analizy obejmuje sześć lat, od 2013 roku do 2018 roku. W pozostałych rozpatrywanych przykładach okres analizy obejmuje 10 lat począwszy od 2009 roku do 2018 roku.

Większa skuteczność metody ważonych współczynników funkcji autokorelacji cząstkowej uzyskiwana jest w porównaniu do obu modeli naiwnych. Zaproponowana

metoda ważonych współczynników funkcji autokorelacji cząstkowej daje większą efektywność w porównaniu do metody naiwnej z opóźnieniem 7 dób, w godzinach 00:00 – 05:00 dla poniedziałków, śród, czwartków, piątków, dni świątecznych i niestandardowych oraz Wigilii Świąt Bożego Narodzenia.

Tab. 4.5.1. Skuteczność prognozowania dla wszystkich godzin doby w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do analizowanych metod i modeli prognostycznych w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

Model	h	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	Św.	Wig.
BPKD	1	2,99	10,17	2,03	1,90	2,10	3,71	10,39	10,75	10,02
	2	19,49	4,34	3,06	3,14	3,59	12,95	11,86	23,13	24,83
SE	1	1,46	8,37	0,59	0,59	0,38	1,69	9,15	8,88	7,72
	2	17,74	2,78	1,72	1,72	1,73	11,45	10,20	21,54	23,18
FR	1	1,51	8,40	0,58	0,65	0,52	2,08	9,47	9,04	7,53
	2	17,80	2,89	1,72	1,59	1,86	11,48	9,87	20,40	21,44
ARIMA	1	2,88	9,73	1,69	1,67	0,82	8,94	10,28	7,67	2,69
	2	17,44	0,64	1,99	1,58	1,83	3,46	9,96	2,54	2,73
MN(-7)	1	-0,09	7,40	-0,85	-0,52	-0,59	0,38	8,02	-1,47	-3,02
	2	15,85	-0,42	0,00	0,18	-0,51	9,83	9,02	-3,43	-1,69
MN(-1)	1	2,35	7,42	-0,51	-8,46	1,43	-5,49	9,59	3,79	2,75
	2	17,69	-14,61	-9,40	-8,27	1,66	10,72	10,63	6,24	3,18

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, 1: godziny od 00:00 do 05:00, 2: godziny od 06:00 do 23:00, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256] i zagranicznych OSP [378], [377].

Wynikiem porównania dla godzin 06:00 – 23:00 są mniejsze błędy prognoz uzyskanych z wykorzystaniem zaproponowanej metody dla wtorków, piątków, dni świątecznych i niestandardowych oraz Wigilii Świąt Bożego Narodzenia. Skuteczność opracowanej metody ważonych współczynników funkcji autokorelacji cząstkowej dla godzin 00:00 – 05:00 w porównaniu z modelem naiwnym z opóźnieniem 1 doby jest większa dla śród, czwartków i sobót, natomiast dla godzin 06:00 – 23:00 dla wtorków, śród i czwartków. Zaproponowana metoda ważonych współczynników funkcji autokorelacji cząstkowej w godzinach 00:05:00 jest mniej skuteczna o wartość poniżej 1,00% w środy, czwartki i piątki dla SEE Szwecji, Finlandii i Francji. W porównaniu do metody ARIMA otrzymywana jest regresja jakości prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej o mniej niż 1,00% w piątki (dla pierwszych sześciu godzin doby) oraz we wtorki (dla pozostałych godzin doby).

Tabela 4.5.2 wskazuje na występowanie co najmniej jednej godziny w obu przedziałach godzinowych dla całego okresu analizy w podziale na poszczególne typy dni. Większa skuteczność opracowanej metody ważonych współczynników funkcji autokorelacji cząstkowej nad analizowanymi modelami odnotowywana jest dla systemu szwedzkiego, francuskiego, modelu ARIMA oraz obu modeli naiwnych. Dla modeli zagranicznych zauważalna poprawa zachodzi dla śród, czwartków i piątków oraz niedziel, natomiast w odniesieniu do grupy metod autoregresyjnych zauważalny trend poprawy efektywności odnotowywany jest dla wtorków, śród, czwartków, piątków sobót, dni świątecznych i niestandardowych oraz Wigilii Świąt Bożego Narodzenia.

Tab. 4.5.2. Skuteczność prognozowania dla wszystkich godzin doby w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do analizowanych metod i modeli prognostycznych w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].

Model	h	pon.	wt.	śr.	czw.	pt.	sob.	niedz.	Św.	Wig.
BPKD	1	-	-	-	-	-	-	-	-	-
	2	-	-	-	-	-	-	-	-	-
SE	1	-	-	-	-	●	-	●	-	-
	2	-	-	●	●	●	-	●	-	-
FR	1	-	-	●	●	●	-	-	-	-
	2	-	-	●	●	●	-	-	-	-
ARIMA	1	-	-	-	-	-	-	-	-	-
	2	-	●	-	-	●	-	-	●	-
MN(-7)	1	●	-	●	●	●	●	-	●	●
	2	-	●	●	●	●	-	-	●	●
MN(-1)	1	-	-	●	●	-	●	-	-	-
	2	-	●	●	●	-	-	-	-	-

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, 1: godziny od 00:00 do 05:00, 2: godziny od 06:00 do 23:00, „●/–”: prognozy bardziej skuteczne/mniej skuteczne w porównaniu do analizowanego modelu lub metody; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256] i zagranicznych OSP [378], [377].

Dni świąteczne i dni niestandardowe - analiza skuteczności

W Tabeli 4.5.3 zamieszczone są wyniki porównawcze skuteczności prognoz metodą ważonych współczynników funkcji autokorelacji cząstkowej za cały okres analizy dla poszczególnych dni świątecznych i niestandardowych. Zastosowanie opracowanej metody daje większą jakość w porównaniu do modelu ARIMA dla godzin od 06:00 do 23:00 dla Poniedziałku Wielkanocnego (27,01%), dla Święta 3. Maja (8,82%) i dla drugiego dnia Świąt Bożego Narodzenia (4,86). Wskazana poprawa skuteczności w porównaniu do modelu ARIMA jest znaczna dla całego rozpatrywanego okresu analizy. Zaproponowana metoda współczynników funkcji autokorelacji cząstkowej daje większą efektywność w porównaniu do metody naiwnej z opóźnieniem 7 dób, w godzinach 00:00 – 05:00 dla Nowego Roku, Poniedziałku Wielkanocnego, dnia 2. Maja, Święta 3. Maja, Bożego Ciała, Wniebowzięcia NMP, Wigilii Bożego Narodzenia oraz pierwszego i drugiego dnia Świąt Bożego Narodzenia.

Porównanie dla godzin 06:00 – 23:00 wskazuje na większą efektywność prognozowania opracowaną metodą ważonych współczynników funkcji autokorelacji cząstkowej dla tych samych dni z wyjątkiem Nowego Roku. Dla pierwszych sześciu godzin doby uzyskiwana poprawa jakości kształtuje się w przedziale od 0,14% do 15,19%. Pozostałe osiemnaście godzin doby w porównaniu do metody naiwnej z opóźnieniem 7 dób poprawia efektywność dzięki zastosowaniu metody ważonych współczynników funkcji autokorelacji cząstkowej w przedziale od 0,57% do 38,07%. Degresja prognoz dla analogicznego porównania poniżej 1,00% otrzymywana jest dla dnia Wszystkich Świętych. Porównanie jakości prognozowania metody ważonych współczynników funkcji autokorelacji cząstkowej z modelem naiwnym z opóźnieniem 1 doby daje poprawę wyłącznie w pierwszych sześciu godzinach doby dla Zielonych Świątków (0,15%) i dla Sylwestra (0,05%). Degresja efektywności poniżej 1,00% w tej analizie odnosi się dla Nowego Roku, Święta Trzech Króli, Bożego Ciała, Wniebowzięcia NMP.

Degresja dla pozostałych godzin doby odnotowywana jest dla Nowego Roku, Święta Trzech Króli, Święta 3. Maja, Bożego Ciała i Sylwestra.

Tab. 4.5.3. Skuteczność prognozowania dla wszystkich godzin doby w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do analizowanych metod i modeli prognostycznych w latach 2009 – 2018, dla dni świątecznych i niestandardowych, wyrażona wartościami błędów MAPE, [%].

Model	h	BPKD	SE	FR	ARIMA	MN(-7)	MN(-1)
S01	1	5,85	2,57	3,47	4,43	-0,14	0,48
	2	15,35	11,14	8,46	11,31	12,14	0,04
S02	1	3,55	2,50	3,04	3,27	1,86	0,58
	2	6,22	4,44	5,63	4,07	3,71	0,65
S03	1	19,59	16,02	15,90	17,47	8,03	7,01
	2	29,30	22,19	21,78	15,98	9,72	9,26
S04	1	7,60	4,90	4,14	2,61	-12,66	3,84
	2	9,38	7,02	5,65	-27,01	-38,07	4,96
S05	1	9,34	7,63	7,83	5,93	6,66	2,24
	2	23,78	18,14	17,57	4,62	20,42	4,21
S06	1	13,15	8,92	9,65	12,42	-3,82	6,76
	2	13,75	9,68	9,62	7,94	-2,26	5,86
S07	1	5,10	3,52	3,80	2,40	-8,99	3,03
	2	10,55	10,64	10,90	-8,82	-16,23	0,60
S08	1	11,84	8,31	10,93	11,87	11,74	-0,15
	2	16,89	15,15	14,40	14,68	14,43	1,12
S09	1	6,24	4,84	5,58	1,11	-0,27	0,29
	2	33,35	27,67	27,81	1,36	-0,57	0,19
S10	1	4,91	4,77	2,43	3,27	-0,48	0,32
	2	23,28	22,94	20,32	1,08	-2,19	3,29
S11	1	11,23	9,71	10,47	9,01	0,58	1,29
	2	33,66	32,89	30,78	7,68	0,75	5,20
S12	1	10,50	9,69	10,12	7,42	6,25	4,23
	2	22,93	19,82	18,70	6,11	5,17	4,38
S13	1	10,02	8,47	8,31	2,69	-3,02	2,75
	2	24,83	21,73	20,23	2,73	-1,69	3,18
S14	1	22,60	20,51	20,27	15,69	-5,95	9,88
	2	43,01	36,06	34,19	11,45	-3,49	27,21
S15	1	17,37	15,44	14,07	13,54	-15,19	15,34
	2	21,63	20,07	19,36	-4,86	-23,55	20,38
S16	1	2,77	3,37	4,19	1,56	0,03	-0,05
	2	10,33	9,91	9,60	7,69	5,88	0,74

Legenda: rob.: dni robocze; wee.: Weekend, Sw.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, 1: godziny od 00:00 do 05:00, 2: godziny od 06:00 do 23:00, „-/+”: błąd prognozowania metodą ważonych współczynników funkcji autokorelacji cząstkowej mniejszy/większy niż dla analizowanego modelu; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256] i zagranicznych OSP [378], [377].

Wyniki zamieszczone w Tabeli 4.5.4 wskazują na występowanie co najmniej jednej godziny w obu przedziałach godzinowych dla całego okresu analizy w podziale na poszczególne dni świąteczne i niestandardowe, charakteryzującą się większą skutecznością prognozowania dzięki zastosowaniu zaproponowanej metody. Większa skuteczność metody ważonych współczynników funkcji autokorelacji cząstkowej w porównaniu do analizowanych modeli odnotowywana jest dla systemu szwedzkiego, fińskiego i francuskiego, modelu ARIMA oraz obu modeli naiwnych. W odniesieniu do modelu ARIMA zauważalny trend poprawy efektywności zaproponowanej metody dla Nowego Roku, drugiego dnia Świąt Wielkiej Nocy, Święta 3. Maja, drugiego dnia

Świąt Bożego Narodzenia oraz Sylwestra. W porównaniu do modelu naiwnego MN(-7) korzystniejsze wyniki prognoz otrzymywane są dla wszystkich dni z wyjątkiem Święta Trzech Króli, Święta 1. Maja, Zielonych Świątków i Święta Niepodległości. Porównanie z modelem naiwnym MN(-1) wskazuje na większą efektywność metody ważonych współczynników funkcji autokorelacji cząstkowej dla wszystkich dni z wyjątkiem Święta Trzech Króli, pierwszego dnia Świąt Wielkiej Nocy, Święta 1. Maja, dnia 2. Maja, dnia Wszystkich Świętych, Święta Niepodległości, Wigilii Świąt Bożego Narodzenia oraz pierwszego i drugiego dnia Świąt Bożego Narodzenia.

Tab. 4.5.4. Skuteczność prognozowania dla wszystkich godzin doby w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do analizowanych metod i modeli prognostycznych w latach 2009 – 2018, dla dni świątecznych i niestandardowych, wyrażona wartościami błędów MAPE, [%].

Model	h	S01	S02	S03	S04	S05	S06	S07	S08	S09	S10	S11	S12	S13	S14	S15	S16
BPKD	1	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
SE	1	-	-	-	-	-	-	-	-	•	•	-	-	-	-	-	-
	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
FR	1	-	-	-	-	-	-	-	-	•	•	-	-	-	-	-	-
	2	•	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
ARIMA	1	•	-	-	•	-	-	•	-	-	-	-	-	-	-	-	-
	2	-	-	-	•	-	-	•	-	-	-	-	-	-	-	•	•
MN(-7)	1	•	-	-	•	-	•	•	-	•	•	-	-	•	•	•	•
	2	•	-	•	•	-	•	•	-	•	•	•	-	•	•	•	•
MN(-1)	1	•	-	-	-	-	-	-	•	•	•	-	-	-	-	-	•
	2	•	-	-	•	-	-	•	-	•	-	-	-	-	-	-	•

Legenda: rob.: dni robocze; wee.: Weekend, Św.: dni świąteczne ruchome i nieruchome, Wig.: Wigilia Bożego Narodzenia, 1: godziny od 00:00 do 05:00, 2: godziny od 06:00 do 23:00, „•/-”: prognozy bardziej skuteczne/mniej skuteczne w porównaniu do analizowanego modelu lub metody; kolor zielony: wynik korzystniejszy dla metody ważonych współczynników funkcji autokorelacji cząstkowej.

Źródło: Opracowanie własne na podstawie danych z witryny internetowej PSE S.A. [256] i zagranicznych OSP [378], [377].

Podsumowanie i wnioski końcowe

Kluczowa dla społeczeństwa i gospodarki ciągłość dostaw energii elektrycznej wynika wprost z zapewnienia bezpiecznej pracy Krajowego Systemu Elektroenergetycznego. Jednym z integralnych elementów zabezpieczenia stabilności jego pracy, jest proces prognozowania zapotrzebowania na moc elektryczną w horyzoncie kolejnej doby. Obecnie stosowane modele prognostyczne, wykorzystujące w procesie prognozowania dane i informacje pochodzące ze źródeł zewnętrznych, są narażone na zakłócenia telekomunikacyjne oraz zagrożenia cybernetyczne, co bezpośrednio wpływa na ryzyko przerwania ciągłości procesów prognozowania, w szczególności w horyzoncie krótkoterminowym. Odpowiedzią na wskazane wyzwania są metody prognozowania typu autoregresyjnego wykorzystujące w procesie prognostycznym wyłączenie dane i informacje o historycznych wartościach prognozowanego parametru. Opracowana metoda ważonych współczynników funkcji autokorelacji cząstkowej może stanowić rozszerzenie grupy modeli prognostycznych stosowanych w codziennych czynnościach prognostycznych przez operatorów systemów elektroenergetycznych, ze szczególnym uwzględnieniem operatorów systemów przesyłowych. Opracowana metoda może stanowić narzędzie prognostyczne wspomagające operatora systemu przesyłowego w sytuacjach zmaterializowania się ryzyka zakłóceń w pozyskiwaniu danych wejściowych do modeli prognostycznych lub w stanach zagrożenia wynikających z ataków cybernetycznych na zarządzaną przez niego sieć teleinformatyczną.

Przeprowadzone w pracy analizy i badania wykazały, że metody autoregresyjne, zarówno naiwne jak i zaawansowane pod względem matematycznym (ARIMA) pozwalają na uzyskanie prognoz dopuszczalnych oraz prognoz dokładnych, a opracowana metoda jest konkurencyjna pod względem uzyskiwanej skuteczności względem nich. Metody naiwne są łatwe w zastosowaniu i pozwalają na osiąganie dopuszczalnych jakościowo prognoz w bardzo krótkim czasie. Metody zaawansowane matematycznie wymagają dłuższego czasu na kalibrację modelu prognostycznego, który rekompensowany jest uzyskiwaniem prognoz dokładnych.

Zmiany technologiczne i legislacyjne zachodzące na światowych i europejskich rynkach energii elektrycznej, w ramach których funkcjonują operatorzy systemów elektroenergetycznych wskazują, że podjęty w pracy obszar badawczy jest istotny i stanowi odpowiedź na wyzwania wynikające ze zidentyfikowanych zmian. Opracowana metoda wpisuje się w trendy i potencjalne zagrożenia oraz stanowi narzędzie odpowiadające na praktyczne potrzeby operatorów systemów elektroenergetycznych.

Badania przeprowadzone w rozprawie potwierdzają, że możliwe jest połączenie zalet obu grup metod autoregresyjnych, czyli współmierności i racjonalności opracowania prognoz dokładnych lub co najmniej dopuszczalnych (spełnienie powyższych cech w kontekście nakładów względem oczekiwanego poziomu jakości). Próba połączenia wskazanych cech i zastosowanie zaawansowanego podłoża matematycznego stanowi zadanie badawcze o dużym obecnym i przyszłym potencjale eksploracji. Opracowany model matematyczny wykorzystujący metodę prognozowania krótkoterminowego

zapotrzebowania na moc elektryczną w systemach elektroenergetycznych, ze szczególnym uwzględnieniem Krajowego Systemu Elektroenergetycznego, cechuje się współmiernością i racjonalnością nakładów względem oczekiwanego poziomu jakości.

W Grupie Kapitałowej PSE S.A. trwają aktualnie testy opracowanego modelu, po których pomyślnym przebiegu możliwe będzie jego operacyjne wdrożenie. Opracowanie w rozprawie modelu bazującego na metodzie prognozowania autoregresyjnego spełniającego sformułowane kryteria stanowi **pozytywną weryfikację pierwszej hipotezy badawczej**.

Na potrzeby realizacji pracy opracowano koncepcję modelu matematycznego i zbudowano jego praktyczną implementację realizującą zagadnienie prognozowania krótkoterminowego zapotrzebowania na moc elektryczną w systemach elektroenergetycznych, który bazuje koncepcyjnie na wartościach współczynników funkcji autokorelacji cząstkowej i tym samym wykorzystuje podejście autoregresyjne. W modelu uwzględniono wymaganą niezależność modelu prognostycznego od danych zewnętrznych i zapewniono wykorzystanie wyłącznie informacji pochodzących z historycznych wartości przebiegu szeregu czasowego zapotrzebowania na moc elektryczną w systemie elektroenergetycznym. Słuszność zastosowania podejścia autoregresyjnego, w opracowaniu narzędzia badawczego, została zweryfikowana w oparciu o przegląd światowych i krajowych publikacji w przedmiotowej tematyce. Zbudowany model matematyczny poddano ponadto procesowi walidacji na danych historycznych: (i) Krajowego Systemu Elektroenergetycznego, (ii) systemów Szwecji i Francji oraz (iii) w odniesieniu do osiemdziesięciu wybranych modeli prognostycznych z grupy metod autoregresyjnych wykorzystujących dane historyczne Krajowego Systemu Elektroenergetycznego. Wyniki analiz pozytywnie zweryfikowały dopuszczalność i jakość opracowywanych prognoz krótkoterminowego zapotrzebowania na moc elektryczną, z uwzględnieniem specyfiki procesu prognostycznego stosowanego w PSE S.A. i w zagranicznych systemach elektroenergetycznych. Zastosowanie opracowanej metody, w porównaniu do wytypowanego zbioru osiemdziesięciu wybranych modeli prognostycznych wykorzystujących podejście autoregresyjne, pozwala na uzyskanie (w wybranych typach dni) prognoz skuteczniejszych (założone kryterium jakości) niż niskonakładowa, względem czasochłonności i kosztów, metoda naiwna oraz skuteczniejszych niż zaawansowana i uznana metoda ARIMA. Opracowana metoda bazująca na ważonych współczynnikach funkcji autokorelacji cząstkowej pozwala na uzyskanie większej skuteczności niż większość wybranych modeli autoregresyjnych poddanych analizie porównawczej, z zachowaniem najmniejszej czasochłonności przy jednoczesnym spełnieniu założonego kryterium dopuszczalności. W związku z powyższym **pozytywnie zweryfikowano drugą hipotezę badawczą**.

Opracowane prognozy zapotrzebowania na moc elektryczną w KSE z wykorzystaniem opracowanej metody spełniają zawężone względem literatury przedmiotu, kryterium dopuszczalności, dla dziewięciu spośród dziesięciu lat okresu analizy *ex post* (lata od 2009 do 2018). Należy podkreślić, że w odniesieniu do dni tygodnia, dla całego dziesięcioletniego okresu analizy, uzyskano prognozy dopuszczalne oraz prognozy

dokładne zarówno dla całej doby, dla pierwszych sześciu godzin doby i pozostałych osiemnastu godzin doby. Prognozy dokładne dla całej doby przypadają w środy i czwartki, prognozy na tym samym poziomie jakości dla pierwszych sześciu godzin doby osiągnięte zostały dla śród, czwartków i piątków, natomiast dla pozostałych osiemnastu godzin doby prognozy dokładne zostały uzyskane dla śród i czwartków. Opracowana metoda, dzięki zastosowaniu hybrydowej integracji z wynikami prognozowania uzyskiwanymi przez PSE S.A., pozwala na zwiększenie wypadkowej skuteczności prognozowania dla całego okresu analizy. Ponadto, w wybranych przypadkach uzyskano większą jakość prognozowania dla systemów elektroenergetycznych Francji i Szwecji, co wskazuje, że opracowana metoda jest elastyczna i nie jest dedykowana jedynie charakterowi przebiegów obciążenia systemu elektroenergetycznego w Polsce.

Wyniki badań zamieszczone w rozprawie wskazują, że opracowana nowa metoda prognozowania krótkoterminowego zapotrzebowania na moc elektryczną jest konkurencyjna wobec metod obecnie stosowanych przez Operatorów Systemów Przesyłowych. Przedstawione wnioski z przeprowadzonych badań stanowią **pozytywną weryfikację trzeciej hipotezy badawczej**. W wyniku przeprowadzonych prac **pozytywnie zweryfikowano wszystkie hipotezy badawcze**.

Zastosowanie opracowanej w pracy metody umożliwia ocenę skuteczności prognoz zapotrzebowania na moc elektryczną w każdej godzinie z wyprzedzeniem jednej doby. Jakość prognoz wyrażaną wartościami błędów MAPE uzyskano poprzez porównanie uzyskanych wartości prognoz z rzeczywistym wykonaniem dla analizowanych szeregów czasowych. Wartości liczbowe określające skuteczność modelu opracowanej metody uzyskano porównując wyniki modelu z wynikami skuteczności dla rozważanych przypadków tj.

- skuteczności otrzymywanej przez Polskie Sieci Elektroenergetyczne S.A. dla Krajowego Systemu Elektroenergetycznego (pierwszy obszar walidacji);
- skuteczności uzyskiwanej przez operatorów szwedzkiego i francuskiego systemu elektroenergetycznego (drugi obszar walidacji);
- skuteczności osiągananej dla osiemdziesięciu wybranych modeli autoregresyjnych (trzeci obszar walidacji).

Otrzymane wyniki dla przedstawionych powyżej obszarów walidacji pozwalają na sformułowanie następujących wniosków:

- Opracowana metoda pozwala uzyskać, w całym dziesięcioletnim okresie, na danych historycznych polskiego systemu elektroenergetycznego, skuteczność kwalifikującą do objęcia przez uzyskiwane prognozy, zawężonych względem doniesień literaturowych, kryteriów dopuszczalności dla wszystkich godzin doby dziewięciu spośród dziesięciu lat analizy, począwszy od 2010 roku do 2018 roku (5,78%). Prognozy dopuszczalne, w odniesieniu do typów dni, uzyskane zostały dla wszystkich godzin doby całego okresu analizy dla piątków (4,03%), dla poniedziałków (4,13%), sobót (4,59%) i wszystkich dni roboczych (4,89%) w pierwszych sześciu godzinach doby oraz dla wtorków (5,04%) i piątków (4,34%) w pozostałych osiemnastu godzinach doby.

- Opracowana metoda pozwala uzyskać, w całym dziesięcioletnim okresie, na danych historycznych polskiego systemu elektroenergetycznego, skuteczność kwalifikującą do objęcia przez opracowywane prognozy kryterium prognoz dokładnych dla śród (3,59%) i czwartków (3,64%) dla wszystkich godzin doby, dla śród (3,10%), czwartków (2,94%) i piątków (3,10%) dla pierwszych sześciu godzin doby oraz dla śród (3,75%) i czwartków (3,87%) dla pozostałych osiemnastu godzin doby.
- Hybrydowa integracja wyników prognoz PSE S.A. i opracowanej metody daje skuteczność prognoz większą niż dla każdej z metod stosowanych odrębnie tj. dla całego dziesięcioletniego okresu analizy (jakość większa o 0,08%), dla każdego roku z osobna (skuteczność większa w przedziale od 0,06% do 0,21%), dla pierwszych sześciu godzin doby (jakość większa w przedziale od 0,09% do 0,61%), dla pozostałych osiemnastu godzin doby (skuteczność większa w przedziale od 0,05% do 0,08%), dla wszystkich typów dni (skuteczność większa w przedziale od 0,02% do 0,18%), dla wszystkich typów dni dla pierwszych sześciu godzin doby (jakość większa w przedziale od 0,02% do 0,31%), dla wszystkich typów dni z wyłączeniem poniedziałków, dla pozostałych osiemnastu godzin doby (jakość większa w przedziale od 0,01% do 0,13%).
- Hybrydowa integracja wyników prognoz PSE S.A. i opracowanej metody, dla całego okresu analizy od 2009 roku do 2018 roku, umożliwia obniżenie błędów MAPE dla całej doby z poziomu 0,82% do 0,74%, dla pierwszych sześciu godzin doby z poziomu 1,02% do poziomu 0,87% oraz dla pozostałych osiemnastu godzin doby z poziomu 0,75% do poziomu 0,69%.
- Skuteczność opracowanej metody w porównaniu do skuteczności osiągananej przez PSE S.A. jest większa w całym dziesięcioletnim okresie analizy w przypadku 16,47% godzin dla pierwszych sześciu godzin doby oraz większa w całym dziesięcioletnim okresie analizy w przypadku 10,61% godzin dla pozostałych osiemnastu godzin doby.
- Opracowana metoda pozwala uzyskać prognozy skuteczniejsze, względem prognoz opracowywanych przez PSE S.A., dla wszystkich typów dni w całym dziesięcioletnim okresie analizy dla pierwszych sześciu godzin doby w przypadku 18,78% godzin dla poniedziałków, 1,18% godzin dla wtorków, 25,49% godzin dla śród, 31,53 godzin dla czwartków, 27,05% godzin dla piątków, 12,80% godzin dla sobót, 1,58% godzin dla niedziel, 20,78% godzin dla wszystkich dni roboczych, 7,10% godzin dla wszystkich dni wolnych od pracy i 4,26% godzin dla wszystkich dni świątecznych.
- Opracowana metoda pozwala uzyskać prognozy skuteczniejsze, względem prognoz opracowywanych przez PSE S.A., dla wszystkich typów dni w całym dziesięcioletnim okresie analizy dla pozostałych osiemnastu godzin doby w przypadku 0,04% godzin dla poniedziałków, 9,74% godzin dla wtorków, 23,10% godzin dla śród, 23,45% godzin dla czwartków, 16,68% godzin dla piątków, 1,18% godzin dla sobót, 2,27% godzin dla niedziel, 14,63% godzin

dla wszystkich dni roboczych, 1,68% godzin dla wszystkich dni wolnych od pracy i 1,46% godzin dla wszystkich dni świątecznych.

- Opracowana metoda pozwala uzyskać, w całym dziesięcioletnim okresie, na danych historycznych zagranicznych systemów elektroenergetycznych, efektywność prognozowania większą dla dwóch systemów:
 - systemu szwedzkiego (0,13% dla piątków w godzinie 00:00; 1,55% dla niedziel w godzinach 00:00 do 05:00; 0,05% i 0,31% dla godzin 22:00 i 23:00 dla śród; 0,24% dla godziny 23:00 dla czwartków; 0,29% dla godziny 23:00 dla piątków; 0,52%, 0,81% i 1,02% dla godzin 21:00, 22:00 i 23:00 dla niedziel),
 - dla systemu francuskiego (0,69%, 0,41%, 1,10% i 0,65% dla godziny 00:00 odpowiednio dla śród, czwartków, piątków, sobót oraz 0,53% i 0,48% dla godziny 05:00 odpowiednio dla śród i czwartków; 1,25%, 1,18% i 0,52% dla godziny 06:00 odpowiednio dla śród, czwartków i piątków oraz 0,24% i 0,5% dla godziny 22:00 dla śród i czwartków).
- Opracowana metoda pozwala uzyskać, w całym dziesięcioletnim okresie, na danych historycznych polskiego systemu elektroenergetycznego, najkrótszy czas budowy modelu (ok. 1 minuta wraz z 67 wybranymi modelami autoregresyjnymi), najkrótszy czas kalibracji (0 minut wraz z 60 wybranymi modelami autoregresyjnymi) oraz najkrótszy czas całkowity (ok. 1 minuta wraz z 54 wybranymi modelami autoregresyjnymi).
- Opracowana metoda, w odróżnieniu od konkurencyjnych wybranych modeli z grupy modeli autoregresyjnych, wyróżnia się prawie bezzwłocznym wskazywaniem wyników prognozy dla każdej godziny z osobna, prawie bezzwłocznym wskazywaniem wyników błędów APE i MAPE prognoz (po zasileniu danymi o historycznym wykonaniu analogicznej doby), prawie bezzwłoczną wizualną interpretacją przeszacowań i niedoszacowań prognoz na wartościach liczbowych, wizualizacją graficzną przebiegów prognozy, rzeczywistego wykonania zapotrzebowania na moc elektryczną oraz błędów MAPE w czasie poniżej 1 minuty. Elastyczność odwzorowania implementacji metody w programie MS Excel® ułatwia wprowadzanie dodatkowych miar oceny jakości prognoz w czasie poniżej jednej minuty dla każdej kolejnej miary (zarówno w trybie *ex ante* jak i *ex post*) przy jednoczesnym zapewnieniu płynności obsługi w programie MS Excel®. Dodatkowo automatyzacja raportowania i tworzenia tabel przestawnych stanowi o sile opracowanego rozwiązania przed przystąpieniem do czynności wdrażających je w środowisku programistycznym wyposażonym w interfejs użytkownika.
- Opracowana metoda pozwala uzyskać, w całym dziesięcioletnim okresie, na danych historycznych polskiego systemu elektroenergetycznego, skuteczność prognozowania (8,29%) większą niż 63,75% modeli prognostycznych z grupy osiemdziesięciu wybranych modeli autoregresyjnych.
- Opracowana metoda pozwala uzyskać, w całym dziesięcioletnim okresie, na danych historycznych polskiego systemu elektroenergetycznego, skuteczność

większą niż pierwszy najskuteczniejszy model prognostyczny z grupy osiemdziesięciu wybranych modeli autoregresyjnych w godzinach od 06:00 do 23:00 dla dni świątecznych Poniedziałku Wielkanocnego, Święta Konstytucji Trzeciego Maja i drugiego dnia Świąt Bożego Narodzenia dla całego okresu analizy. Pierwszym najskuteczniejszym modelem prognostycznym z grupy osiemdziesięciu wybranych modeli jest model ARIMA. Uzyskana przewaga jakości dla wskazanych dni kształtuje się na poziomie odpowiednio: 27,01%, 8,82% i 4,86%.

- Opracowana metoda pozwala uzyskać, w całym dziesięcioletnim okresie, na danych historycznych polskiego systemu elektroenergetycznego, skuteczność większą niż drugi najskuteczniejszy model prognostyczny z grupy osiemdziesięciu wybranych modeli autoregresyjnych w godzinach od 00:00 do 06:00 dla dziewięciu z szesnastu dni świątecznych i niestandardowych oraz w godzinach w godzinach od 06:00 do 23:00 dla ośmiu dni tej samej grupy typów dni. W pierwszych sześciu godzinach doby większa skuteczność uzyskanych prognoz dotyczy Nowego Roku, Poniedziałku Wielkanocnego, dnia drugiego Maja i Święta Konstytucji Trzeciego Maja, Święta Bożego Ciała, Święta Wniebowzięcia NMP, Wigilii Świąt Bożego Narodzenia oraz pierwszego i drugiego dnia tych świąt. Uzyskana przewaga jakości dla wskazanych dni kształtuje się na poziomie od 0,14% do 15,19%. Przewaga skuteczności opracowanej metody za cały okres analizy dla wszystkich dni świątecznych i niestandardowych w pierwszym zakresie godzin doby wynosi 0,96%. W pozostałych osiemnastu godzinach doby większa efektywność uzyskanych prognoz dotyczy tych samych dni z wyjątkiem Nowego Roku. Uzyskana przewaga skuteczności dla wskazanych dni kształtuje się na poziomie odpowiednio od 0,57% do 38,07%. Przewaga skuteczności opracowanej metody za cały okres analizy dla wszystkich dni świątecznych i niestandardowych w drugim zakresie godzin doby wynosi 0,99%.
- Opracowana metoda pozwala uzyskać, w całym dziesięcioletnim okresie, na danych historycznych polskiego systemu elektroenergetycznego, skuteczność większą niż szósty najskuteczniejszy model prognostyczny z grupy osiemdziesięciu wybranych modeli autoregresyjnych. Szóstym najskuteczniejszym modelem prognostycznym z grupy osiemdziesięciu wybranych modeli jest model naiwny z opóźnieniem jednej doby. Powodem wyboru tego modelu do analizy porównawczej jest fakt przynależności do grupy metod naiwnych, dla których model z opóźnieniem jednej doby daje drugie w kolejności najskuteczniejsze wyniki prognoz w grupie wybranych osiemdziesięciu autoregresyjnych modeli prognostycznych.

W wyniku przeprowadzonych prac badawczych **zrealizowano wszystkie założone cele cząstkowe**. W pierwszej kolejności zidentyfikowano dynamiczne zmiany zapotrzebowania na moc elektryczną w KSE i konieczność opracowania nowej autoregresyjnej metody prognozowania zapotrzebowania na moc elektryczną w tym systemie. Następnie, na podstawie przygotowanej koncepcji (metoda równań

Yule – Walker’a), opracowano autoregresyjną metodę prognozowania i spośród dwóch opracowanych sposobów obliczania ważonych współczynników funkcji autokorelacji cząstkowej zbudowano model najkorzystniejszy pod względem uzyskiwanej skuteczności prognozowania (podejście klasyczne). W kolejnym kroku określono kryteria dopuszczalności prognoz, opracowano prognozy wygasłe *ex post* zapotrzebowania na moc elektryczną w KSE dla każdej godziny doby za okres dziesięciu lat począwszy od 2009 roku do 2018 roku w podziale na pierwsze sześć godzin doby i pozostałych osiemnaście godzin doby. Ponadto, przeprowadzono symulację hybrydowej integracji wyników prognoz opracowywanych przez PSE S.A. w powiązaniu z wynikami uzyskanymi z wykorzystaniem opracowanej metody. Następnie oceniono efektywność prognozowania z wykorzystaniem danych systemu elektroenergetycznego Szwecji i Francji. Finalnie ocenie poddano skuteczność prognoz *ex post* zapotrzebowania na moc elektryczną w KSE przy zastosowaniu opracowanej metody prognozowania, na tle wybranych autoregresyjnych metod prognozowania.

Wszystkie powyższe działania umożliwiły **realizację głównego celu badań**, a mianowicie opracowanie autoregresyjnej metody do prognozowania zapotrzebowania na moc elektryczną, cechującą się co najmniej dopuszczalną jakością prognoz (tj. wartościami błędu $4,00\% < MAPE \leq 6,00\%$), ze szczególnym uwzględnieniem pierwszych sześciu godzin doby oraz dla dni świątecznych i niestandardowych.

Nadrzędną potrzebą PSE S.A., w kontekście opracowywania prognoz z wyprzedzeniem jednej doby, jest zapewnienie wielości i różnorodności dostępnych prognoz, możliwe krótkiego czasu ich opracowywania oraz co najmniej dopuszczalnej jakości. Zaproponowana metoda wypełnia wskazane potrzeby.

Przeprowadzone w rozprawie analizy i uzyskane wyniki pozwalają na sformułowanie **kierunków dalszych badań**. Zarówno złożoność jak i wieloaspektowość zagadnienia z uwzględnieniem podziału na dwa przedziały godzin doby powodują, że analizą o podobnym do przedmiotowego zakresie należałoby poddać również graniczne odchylenia skuteczności opracowanych prognoz, które mogą wpływać na ich uśrednioną skuteczność. Niezbędne byłoby w tym przypadku rozwinięcie modelu matematycznego poprzez wprowadzenie funkcji kary, która umożliwiłaby minimalizację wartości odchyżeń granicznych, czyli maksymalnych niedoszacowań i przeszacowań prognoz. Drugi zasadny kierunek badawczy obejmuje automatyzację doboru najkorzystniejszego opóźnienia czasowego uwzględnianego dla obu opracowanych podejść realizacyjnych opracowanej metody oraz optymalizację wyboru korzystniejszego podejścia dla każdej doby. Trzecim zasadnym kierunkiem badawczym jest zweryfikowanie przydatności opracowanej metody dla prognozowania w horyzoncie dłuższym od jednej doby.

Doskonalenie opracowanej metody, wraz z poszerzeniem warsztatu narzędziowego wspierającego proces prognozowania krótkoterminowego zapotrzebowania na moc elektryczną, ma coraz większe znaczenie w związku z przewidywanym zagęszczeniem granulacji prognoz, opracowywanych przez PSE S.A. w ramach planów BPKD, z piętnastu minut do pięciu minut. W związku z powyższym, podjęte zostały działania mające na celu opracowanie prototypu prognostycznego implementującego opracowaną metodykę, niezależnego od zewnętrznych narzędzi symulacyjnych i prognostycznych.

Bibliografia

1. Akademia Podlaska. 2002. *Sztuczna inteligencja - Materiały V Konferencji Naukowej*. Materiał opracowany przez Instytut Informatyki Akademii Podlaskiej, Instytut Podstaw Informatyki Polskiej Akademii Nauk i Wydział Cybernetyki Wojskowej Akademii Technicznej. Wydawnictwo Akademii Podlaskiej. Siedlce.
2. Al-Fuhaid A. S., El-Sayed M. A., Mahmoud M.S. 1997. *Neuro-Short-Term Load Forecast of the Power System in Kuwait*. Department of Electrical and Computer Engineering Kuwait University, Safat, Kuwait. *Applied Mathematical Modelling* 1997, 21:215-219, April, 1997 by Elsevier Science Inc.
3. Almehaiei E., Soltan H. 2011. *A Methodology for Electric Power Load Forecasting*. Alexandria Engineering Journal Vol. 50. Elsevier Ltd. Pp. 137-144.
4. Alonso A.M., Garcia-Martos C. 2012. *Time-Series Analysis, Moving Average and ARMA Processes*. Universidad Carlos III de Madrid, Universidad Politecnica de Madrid, June, July, 2012.
5. Al-Shobaki S., Mohsen M. 2008. *Modeling and Forecasting of Electrical Power Demands for Capacity Planning*. Elsevier Ltd. *Energy Conversion and Management*. *Energy Conversion and Management* 49 (2008) 3367-3375.
6. Aman S., Chelmiss C., Prasanna V. 2014. *Addressing Data Veracity in Big Data Applications*. 2014 IEEE International Conference on Big Data. Wydawnictwo IEEE.
7. Aurangzeb K. 2019. *Short Term Power Load Forecasting Using Machine Learning Models for Energy Management in a Smart Community*. Wydawnictwo IEEE.
8. Baczyński D. 2010. *Zastosowanie algorytmu optymalizacji rojem cząstek w procesie uczenia sztucznej sieci neuronowej w prognozowaniu krótkoterminowym*. Rynek Energii 4/2010.
9. Badran S. M., Abouelatta O. B. 2012. *Forecasting Electrical Load Using ANN Combined with Multiple Regression Method*. The Research Bulletin of Jordan ACM, Volume II (II).
10. Banasiak P., Gorczyca-Goraj A., Przygodzki M. 2017. *Analiza grafików obciążeń wybranego segmentu odbiorców niskiego napięcia*. Politechnika Śląska. Energetyka 2017.
11. Banaszekiewicz B. 2003. *Zastosowania metod statystycznych w badaniach naukowych II. Zmienność temperatury powietrza i opadów atmosferycznych w Polsce północnej i jej wpływ na produktywność rolniczą klimatu*. Katedra Meteorologii i Klimatologii, Uniwersytet Warmińsko-Mazurski w Olsztynie, StatSoft Polska, Kraków. 2003.
12. Bansal P., Salling J. 2013. *Multivariate Adaptive Regression Splines (MARS)*. UT ECE. 16-Feb-2013.
13. Barron A. R., Xiao X. 1991. *Multivariate Adaptive Regression Splines*. The Annals of Statistics, Vol. 19, No. 1 (Mar., 1991), Institute of Mathematical Statistics, JSTOR, Department of Statistics, Stanford University, Stanford, CA 94305-4065. Pp. 67-82.
14. Bartkiewicz W. 2011. *Metody określania niepewności prognoz krótkoterminowego obciążenia sieci dla modeli neuronowych i neuronowo - rozmytych*. Rynek Energii, nr 1 (92), luty 2011. Str. 41-46.
15. Bartkiewicz W. 2013. *Modelowanie krótkoterminowego popytu na energię elektryczną z wykorzystaniem sieci neuronowych i neuronowo - rozmytych*. Katedra Informatyki, Wydział Zarządzania, Uniwersytet Łódzki. Wydawnictwo Uniwersytetu Łódzkiego. www.wydawnictwo.uni.lodz.pl.
16. Bartkiewicz W., Matusiak B. 2004. *Sieci neuronowe i algorytmy genetyczne a krótkookresowe prognozowanie zużycia na rynku energii*. w: J.S. Zieliński - 50 lat pracy naukowej. Wydawnictwo Biblioteka, 2004. Str. 345-353.
17. Bartodziej G., Tomaszewski M. 2009. *Polityka energetyczna i bezpieczeństwo energetyczne*. Wydawnictwo „Nowa Energia”. Racibórz. 2009.
18. Bazzan A. L. C., Labidi S. (Eds.). 2004. *Advances in Artificial Intelligence*. 17th Brazilian Symposium on Artificial Intelligence, São Luis, Maranhão, Brazil, September 29 - October 1, 2004, Proceedings. Springer Berlin, Heidelberg, New York, New York, 2004. - SBIA 2004. Pp. 317-325.
19. Belsley D. A., Kuh E., Welsch R. E. 1980. *Regression Diagnostics: Identifying Influential Data and Sources of Collinearity*. Wiley. New York, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
20. Bian H. 2012. *SPSS Discriminant Function Analysis*. Office for Faculty Excellence.

21. Borchers B. 2001. *The Partial Autocorrelation Function*. www.ees.nmt.edu-pac. April 4, 2001.
22. Borgosz-Koczwarą M., Kozłowski M., Misiorek A., Piesiewicz T. 2001. *Analiza metod prognozowania procesu zapotrzebowania na energię elektryczną*. Energetyka. Nr 12. Str. 759-764.
23. Box G. E. P., Jenkins G. M. 1976. *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day.
24. Brodowski S., Bielecki A., Filocha M. 2017. *A Hybrid System for Forecasting 24-h Power Load Profile for Polish Electric Grid*. Applied Soft Computing 58 (2017) 527-539. Contents lists available at ScienceDirect. 1568-4946/c 2017 Elsevier B. V. Applied Soft Computing.
25. Broszkiewicz-Suwaj E., Wyłomańska A. 2004. *Periodic Correlation vs. Integration and Cointegration (Okresowa korelacja a integracja i kointegracja)*. Institute of Mathematics, Wrocław University of Technology, Poland.
26. Buitrago J., Asfour S. 2017. *Short-Term Forecasting of Electric Loads Using Nonlinear Autoregressive Artificial Neural Networks with Exogenous Vector Inputs*. University of Miami, Department of Industrial Engineering. 1 January 2017. Energies 2017, 10, 40.
27. Cabena, P., Hadjinian, P., Stadler, R., Verhees, J., Zanasi, A. 1998. *Discovering Data Mining. From Concept to Implementation*. Upper Saddle River, Wydawnictwo NJ: Prentice Hall.
28. Ceperic E., Ceperic V., Baric A. 2013. *A Strategy for Short-Term Load Forecasting by Support Vector Regression Machines*. IEEE Transactions on Power Systems 1. 0885-8950/\$31.00 © 2013 IEEE. June 13, 2013. Paper no. TPWRS-01289-2012.
29. Cetron M. J., Ralph C. R. 1978. *Prognozowanie rozwoju przemysłu*. Wydawnictwa Naukowo-Techniczne. Warszawa. 1978.
30. Chahkoutahi F., Khashei M. 2017. *A Seasonal Direct Optimal Hybrid Model of Computational Intelligence and Soft Computing Techniques for Electricity Load Forecasting*. Energy 140 (2017) 988e1004, Energy. © 2017 Elsevier Ltd. All rights reserved. 0360-5442/© 2017 Elsevier Ltd.
31. Chapagain K., Kittipiyakul S. 2016. *Short - Term Electricity Load Forecasting Model and Bayesian Estimation for Thailand Data*. MATEC Web of Conferences 55, 06003 (2016). ACPEE 2016.
32. Chen H., Canizares C. A., Singh A. 1999. *ANN-Based Short-Term Load Forecasting in Electricity Markets*. University of Waterloo Department of Electrical & Computer Engineering, Waterloo, Ontario, Canada, 1999.
33. Chheepa T. K., Manglani T. 2017. *A Critical Review on Employed Techniques for Short Term Load Forecasting*. International Research Journal of Engineering and Technology (IRJET). Volume: 04 Issue: 06, June, 2017. p-ISSN: 2395-0072.
34. Chollet F., Allaire J. J. 2019. *Deep Learning - Praca z językiem R i Biblioteką Keras*. Wydawnictwo Helion. Gliwice. 2019.
35. Cieślak M. (red.). 2005. *Prognozowanie gospodarcze. Metody i zastosowania*. Wydawnictwo Naukowe PWN, Warszawa, 2005.
36. Cieślak M. 1997. *Prognozowanie gospodarcze - metody i zastosowania*. Wydawnictwo Naukowe PWN, Warszawa, 1997.
37. Clements A. E., Hurn A. S., Li Z. 2015. *Forecasting Day-Ahead Electricity Load Using a Multiple Equation Time Series Approach*. NCER Working Paper Series. Working Paper #103, September 2014, Revision May 2015. School of Economics and Finance, Queensland University of Technology. JEL Classification Numbers. C32; Q41; Q47.
38. Conway D., Myles J., White J. M. 2015. *Uczenie maszynowe dla programistów*. Wydawnictwo Helion/O'Reilly. Gliwice. 2015.
39. Correa E., Inga E., Inga J., Hincapié R. 2017. *Electrical Consumption Pattern base on Meter Data Management System using Big Data Techniques*. 2017 International Conference on Information Systems and Computer Science. Wydawnictwo IEEE.
40. Cottrell A., Lucchetti R. 2015. *Gretl User's Guide - Gnu Regression, Econometrics and Time - Series Library*. April, 2015. (gretl-guide).
41. Czapaj R. 2009. *Krótkoterminowe prognozowanie cen energii elektrycznej na wybranych polskich parkietach obrotu energią elektryczną z uwzględnieniem walorów wybranych europejskich parkietów obrotu energią elektryczną przy wykorzystaniu sieci neuronowych*. Praca dyplomowa - Studia podyplomowe, zaoczne, 1 - roczne. Uniwersytet Ekonomiczny w Krakowie i StatSoft Polska - czerwiec 2009.

42. Czapaj R. 2009. *O możliwości krótkoterminowego prognozowania cen energii elektrycznej na polskich parkietach obrotu z uwzględnieniem indeksu niemieckiej giełdy EEX AG*. Przegląd Elektrotechniczny, R. 85, NR 3/2009. Str. 140-143.
43. Czapaj R. 2012. *Analiza czynników decydujących o stratach energii w sieci przesyłowej*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2012.
44. Czapaj R. 2017. *Typowanie zmiennych objaśniających przy wykorzystaniu zautomatyzowanych metod statystycznych jako sposób optymalizacji wyboru metody estymacji szczytowego dobowego obciążenia KSE*. Przegląd Elektrotechniczny, R. 93, NR 4/2018. Str. 58-61.
45. Czapaj R., Bojda-Mglej K., Kochanowska K., Gorczyca-Goraj A. 2020. *Wskaźniki jakości danych pomiarowych dla potrzeb wdrożenia Operatora Informacji Pomiarowej*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2020.
46. Czapaj R., Bojda-Mglej K., Mrowiec D. 2019. *Ocena wpływu rezygnacji ze zmiany czasu na prognozy zapotrzebowania na moc i energię elektryczną*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2019.
47. Czapaj R., Gwóźdź R., Przygrodzki M. 2006. *Analiza techniczna i fundamentalna a dokładność prognozy cen energii elektrycznej na rynku giełdowym*. Przegląd Elektrotechniczny, R. 82 NR 9/2006.
48. Czapaj R., Kamiński J., Benalcazar P. 2018. *Dobór zmiennych objaśniających z wykorzystaniem metody MARSplines na przykładzie prognozowania dobowego zapotrzebowania na moc szczytową 15-minutową w KSE*. XIV Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce PE'18. (Materiały Konferencyjne). Podlesice. 2018.
49. Czapaj R., Kamiński J., Benalcazar P. 2018. *Dobór zmiennych objaśniających z wykorzystaniem metody MARSplines*. XIV Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce PE'18. (Materiały konferencyjne). Podlesice. 2018.
50. Czapaj R., Kamiński J., Benalcazar P. 2018. *Prognozowanie krótkoterminowe z wykorzystaniem metody MARSplines*. XIV Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce PE'18. (Materiały konferencyjne). Podlesice. 2018.
51. Czapaj R., Kamiński J., Benalcazar P. 2018. *Prognozowanie krótkoterminowe zapotrzebowania na energię elektryczną w KSE z wykorzystaniem metody MARSplines*. XIV Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce PE'18. Wydawnictwo Politechniki Częstochowskiej (Materiały konferencyjne). Podlesice. 2018.
52. Czapaj R., Kamiński J., Benalcazar P. 2019. *Dobór zmiennych objaśniających z wykorzystaniem metody MARSplines na przykładzie prognozowania dobowego zapotrzebowania na moc szczytową 15-minutową w KSE*. Przegląd Elektrotechniczny, R. 95, NR 8/2019. str. 9-12.
53. Czapaj R., Kamiński J., Benalcazar P. 2019. *Evaluation of the Application of a Forecasting Model Using the Classic Least Squares Method in Forecasting Daily 15-Minute Peak Power Demand in the National Power System*. Acta Energetica, Nr 1/38 (2019). Pp. 45-51.
54. Czapaj R., Kamiński J., Benalcazar P. 2019. *Prognozowanie 15-minutowego szczytowego dobowego zapotrzebowania na moc w KSE z wykorzystaniem metody najmniejszych kwadratów*. Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej Nr 62. Str. 45-48.
55. Czapaj R., Kamiński J., Benalcazar P. 2019. *Prognozowanie 15-minutowego szczytowego dobowego zapotrzebowania na moc w KSE z wykorzystaniem metody najmniejszych kwadratów*. Acta Energetica, Nr 1/38 (2019). Str. 52-57.
56. Czapaj R., Kamiński J., Benalcazar P. 2019. *Prognozowanie krótkoterminowe zapotrzebowania na energię elektryczną w KSE z wykorzystaniem metody MARSplines*. Przegląd Elektrotechniczny, R. 95, NR 7/2019. str. 133-136.
57. Czapaj R., Ponikowska T., Kozakiewicz M. 2020. *Optymalizacja metodyki prognozowania oraz interfejsu użytkownika w narzędziu informatycznym służącym do prognozowania strat sieciowych (Etap I)*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2020.
58. Czapaj R., Ponikowska T., Kozakiewicz M. 2020. *Optymalizacja metodyki prognozowania oraz interfejsu użytkownika w narzędziu informatycznym służącym do prognozowania strat sieciowych (zadanie w ramach projektu Poszukiwanie i proponowanie rozwiązań innowacyjnych zmierzających do zapewnienia bezpiecznej i ekonomicznej pracy KSE z uwzględnieniem bieżących potrzeb PSE S.A.)*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2020.
59. Czapaj R., Rzepka P., Szablicki M. 2016. *Typowanie zmiennych objaśniających przy wykorzystaniu zautomatyzowanych metod statystycznych jako sposób optymalizacji wyboru metody estymacji*

- szczytowego dobowego obciążenia KSE. XIII Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce PE'16. Wydawnictwo Politechniki Częstochowskiej (Materiały konferencyjne). Podlesice, 2016.
60. Czapaj R., Sołtysik M. 2019. *Przegląd metod/reguł/algorytmów walidacyjnych danych pomiarowych systemu elektroenergetycznego uwzględniających procesy identyfikacji, zastępowania, uzupełniania i eliminacji danych dla potrzeb wdrożenia Operatora Informacji Pomiarowej*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2019.
 61. Czapaj R., Szablicki M., Rzepka P., Sołtysik M. *Prognozowanie krótkoterminowe profili odbiorczych i zdolności wytwórczych w klastrach energii*. Przegląd Elektrotechniczny, R. 95 NR 7/2019.
 62. Czyżycki R., Klóska R. 2011. *Ekonometria ekonometrycznych w przykładach i zadaniach*. Wydawnictwo ECONOMICUS, Szczecin.
 63. Dąsał K. 2002. *Dobór zmiennych wejściowych do Modelu Rozkładu Kanonicznego*. Wydawnictwo Politechniki Częstochowskiej. VI Konferencja Naukowa Prognozowanie w Elektroenergetyce, Prognozowanie, Efektywność Energetyczna. Częstochowa - Złoty Potok, 18 - 20 Września 2002 r.
 64. Dąsał K. 2002. *Metoda doboru wejść w prognozowaniu krótkoterminowym obciążeń systemu elektroenergetycznego dla modelu rozkładu kanonicznego wektora losowego*. Częstochowa 2002. Rozprawa doktorska.
 65. Dąsał K., Popławski T., Rusek K. 2013. *Problem wyboru zmiennych opóźnionych w modelu*. (Prognozowanie w elektroenergetyce 2013). Wydawnictwo Politechniki Częstochowskiej. Politechnika Częstochowska. Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce. Przegląd Elektrotechniczny.
 66. Demski T. 2006. *Co statystyka i wykresy mogą powiedzieć o procesie?* (materiał: *Zastosowania statystyki i Data Mining*), Wydawnictwo StatSoft Polska Sp. z o.o., Kraków.
 67. Demski T. 2006. *Data Mining I - kurs podstawowy*. Materiały kursowe StatSoft Polska. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. 27 - 28 marca.
 68. Demski T. 2006. *Przykład prognozowania z wykorzystaniem metod Data Mining (materiał: STATISTICA 8 bliżej Ciebie)*. Wydawnictwo StatSoft Polska Sp. z o.o., Kraków.
 69. Departament Rozwoju Systemu PSE S.A. 2016. *PSE S.A. - Prognoza pokrycia zapotrzebowania szczytowego na moc w latach 2016-2035*. Konstancin-Jeziorna. 20 maja 2016.
 70. Dittmann P., Szabela-Pasierbińska E., Dittmann I., Szpulak A. 2009. *Prognozowanie w zarządzaniu przedsiębiorstwem*. Oficyna a Wolters Kluwer Business. Kraków.
 71. Dżaków P. 2015. Sierpień i lato 2015 w Polsce. Witryna internetowa <http://meteomodel.pl>.
 72. Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo-Techniczne. Warszawa. 1971.
 73. Dobrzańska I. 1960. *Zmienność momentów występowania obciążeń charakterystycznych doby roboczej*. Instytut Energetyki. N. 106. Katowice, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
 74. Dobrzańska I. 1961. *Wpływ czasu letniego na wykres obciążenia dobowego systemów energetycznych w Polsce*. Instytut Energetyki. Katowice, w: Dobrzańska I. (pod red.). Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
 75. Dobrzańska I. 1962. *Zmienność obciążeń systemów energetycznych ich analiza i metoda prognozy na przykładzie zespołu systemów polskich*. Dysertacja. Instytut Energetyki. N. 266. Katowice, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo-Techniczne. Warszawa. 1971.
 76. Dobrzańska I. 1964. *Analiza zmienności obciążeń polskiego systemu energetycznego*. Biul. Inst. Energetyki. Energetyka 1963. Z. 8 i 10, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
 77. Dobrzańska I. 2012. *Prognozowanie w elektroenergetyce. Zagadnienia wybrane*. red. I. Dobrzańska, Wydawnictwo Politechniki Śląskiej, Częstochowa 2012.

78. Dobrzańska I., Dąsał K., Łyp J., Popławski T., Sowiński J. 2002. Prognozowanie w elektroenergetyce - zagadnienia wybrane. Wydawnictwo Politechniki Częstochowskiej, Częstochowa 2002.
79. Dołęga W. 2009. *Zapewnienie bezpieczeństwa elektroenergetycznego*. Energetyka Ciepła i Zawodowa, Nr. 11/2009. Racibórz. 2009.
80. Dołęga W. 2015. *Aktualne wymagania dotyczące metodyki planowania rozwoju sieciowej infrastruktury elektroenergetycznej*. Rynek Energii - Rozwój rynku a konkurencyjność gospodarki (red. Połecki Z.). Lublin. 2015.
81. Dołęga W. 2020. *Awarie sieciowe i systemowe w krajowej sieci przesyłowej*. Elektro Info. Nr. 1-2/2020. Warszawa. 2020.
82. Dong X., Qian L., Huang L. 2017. *A CNN Based Bagging Learning Approach to Short-Term Load Forecasting in Smart Grid*. Wydawnictwo IEEE.
83. Dudek G. 2004. *Wybrane metody analizy szeregów czasowych obciążeń elektroenergetycznych*. Wydawnictwo Politechniki Częstochowskiej. Politechnika Częstochowska. VII Konferencja Naukowa Prognozowanie w Elektroenergetyce. Częstochowa - Złoty Potok, 23 - 24 Września 2004 r.
84. Dudek G. 2006. *Krótkoterminowe prognozowanie zapotrzebowania na moc elektryczną metodą klasteryzacji rozmytej*. Przegląd Elektrotechniczny, nr 82, 2006. Str. 26-28.
85. Dudek G. 2008. *Analiza podobieństwa obrazów sekwencji szeregów czasowych obciążeń elektroenergetycznych*. Wydawnictwo Politechniki Częstochowskiej. Politechnika Częstochowska. IX Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce. Wisła Potok, 17 - 19 Września 2008 r.
86. Dudek G. 2009. *Analiza podobieństwa obrazów sekwencji szeregów czasowych obciążeń elektroenergetycznych*. Przegląd Elektrotechniczny, ISSN 0033-2097, R. 85 NR 3/2009. Str. 149-152.
87. Dudek G. 2009. *Prognozowanie krótkoterminowe obciążeń systemów elektroenergetycznych z wykorzystaniem estymatorów najbliższego sąsiedztwa*. Konferencja Naukowa Aktualne Problemy w Elektroenergetyce - Materiały Konferencyjne, 3 - 5 czerwca 2009, Jurata.
88. Dudek G. 2010. *Short-Term Load Forecasting Based on Kernel Conditional Density Estimation*. Czestochowa University of Technology. Przegląd Elektrotechniczny (Electrical Review), ISSN 0033-2097, R. 86 NR 8/2010.
89. Dudek G. 2011. *Neuro - fuzzy approach to the next Day Load Curve Forecasting*. Przegląd Elektrotechniczny, 2011. Str. 61 - 64.
90. Dudek G. 2011. *Optymalizacja modelu regresji jądrowej do krótkoterminowego prognozowania obciążeń systemów elektroenergetycznych*. XI Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce PE'11, Wisła, 14 - 16 września 2011. Wydawnictwo Politechniki Częstochowskiej (materiały konferencyjne). Częstochowa 2011.
91. Dudek G. 2015. *Similarity-based Approaches to Short-term Load Forecasting*. Electrical Department, Czestochowa University of Technology, Poland. Applied Soft Computing 37:277 - 287. December.
92. Dudek G. 2016. *Drzewa regresyjne i lasy losowe jako narzędzia predykcji szeregów czasowych z wahaniami sezonowymi*. Politechnika Częstochowska, Wydział Elektryczny, Instytut Informatyki. VI spotkanie Polskiej Grupy Badawczej Systemów uczących się. Częstochowa, 14.04.2016.
93. Dudek G. 2016. *Pattern - Based Local Linear Regression Models for Short - Term Load Forecasting*. Czestochowa University of Technology, Department of Electrical Engineering. Electric Power System Research (Elsevier), vol. 130, 2016. Pp. 139-147.
94. Dudek G., Janicki M. 2016. *Nearest Neighbour Model with Weather Inputs for Pattern-Based Electricity Demand Forecasting*. XIII Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce. Podlesice 6 - 8 kwietnia, 2016.
95. Dudek G., Janicki M. 2017. *Nearest Neighbour Model with Weather Inputs for Pattern - Based Electricity Demand Forecasting*. Czestochowa University of Technology, Department of Electrical Engineering. Przegląd Elektrotechniczny, ISSN 0033-2097, R. 93 NR 3/2017.
96. Dwijayanti S., Hagan M. 2013. *Short Term Load Forecasting Using A Neural Network Based Time Series Approach*. First International Conference on Artificial Intelligence, Modelling & Simulation. 978-1-4799-3251-1/13 \$31.00© 2013 IEEE.

97. Dyka E., Mróz-Radłowska. 2016. *Ekonomia w energetyce*. Wydawnictwo Politechniki Łódzkiej, Łódź.
98. Dział Słownictwa Technicznego Wydawnictw Naukowo-Technicznych. 1985. *Słownik elektroniczny polsko-angielsko-rosyjski*. Wydawnictwa Naukowo-Techniczne. Warszawa. 1985.
99. Engle. R.F. 1982. *Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of U.K. Inflation*. "Econometrica". Vol. 50. Pp. 987-1007, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
100. Esener I. I., Yuksel T., Kurban M. 2015. *Short-Term Load Forecasting without Meteorological Data Using AI-based Structures*. Turkish Journal of Electrical Engineering & Computer Sciences. (2015) 23: 370 - 380. Department of Electrical and Electronics Engineering, Bilecik Seyh Edebali University, Bilecik, Turkey.
101. Eshel G. 2011. *Spatiotemporal Data Analysis*. Princeton University Press, 338 pp., Dec. 2011.
102. Eshel G. 2011. *The Yule Walker Equations for the AR Coefficients*. Wharton University of Pennsylvania.
103. Fan S., Hyndman R. J. 2010. *Short-Term Load Forecasting Based on a Semi-Parametric Additive Model*. IEEE Transactions On Power Systems. August 2010.
104. Farahat M. A., Elgawed A. F. A., Ibrahim A., Mustafa H. M. M. 2014. *Short Term Load Forecasting Using Neural Networks and Particle Swarm Optimization*. Journal of Electrical Engineering. 2014.
105. Filik U. B., Kurban M. 2007. *A New Approach for the Short-Term Load Forecasting with Autoregressive and Artificial Neural Network Models*. International Journal of Computational Intelligence Research. ISSN 0973-1873 Vol.3, No.1 (2007), pp. 66-71. Research India Publications.
106. Fisz M. 1967. *Rachunek prawdopodobieństwa i statystyka matematyczna*. PWN. Warszawa, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo-Techniczne. Warszawa. 1971.
107. Friedman J. H. 1991. *Multivariate Adaptive Regression Splines*. The Annals of Statistics, Vol. 19, No. 1 (Mar., 1991), pp. 1-67 Published by: Institute of Mathematical Statistics Stable.
108. Friedman J. H. 1993. *Fast MARS. Technical Report No. 110*. May 1993. Laboratory for Computational Statistics, Department of Statistics, Stanford University.
109. Friedman J. H. 1993. *Laboratory for Computational Statistics. Fast MARS*. Department of Statistics, Stanford Linear Accelerator Center, Stanford University, Stanford, CA 94305-4065. Technical Report No. 110, May 1993.
110. Friedman J.H. 1990. *Multivariate Adaptive Regression Splines. Department of Statistics*. Stanford Linear Accelerator Center, Stanford University, Stanford, CA 94305-4065. SLAC Pub-460, Rev, Tech Report 102 Rev, August 1990. Laboratory for Computational Statistics.
111. Friedman M. 1953. *The Methodology of Positive Economics, in: Essays in Positive Economics*. University of Chicago Press. Chicago. Str. 14.
112. Friedman M., Meiselman D. 1963. *The Relative Stability of Monetary Velocity and the Investment Multiplier in the U.S*. Pp. 1897-1958, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
113. Frisch R. 1934. *Statistical Confluence Analysis by Means of Complete Regression Systems*. University Economics Institute. Oslo, w: Maddala G. S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
114. Gabaldón A., Ruiz-Abellón M. C., Fernández-Jiménez L. A. 2020. *Short-Term Load Forecasting 2019*. Energies, A Special Issue: ISSN 1996-1073; Section A5: Smart Grids and Microgrids.
115. Gabaldón A., Ruiz-Abellón M. C., Fernández-Jiménez L. A. 2021. *Short-Term Load Forecasting 2021*. Energies, A Special Issue: ISSN 1996-1073; Section A: Electrical Engineering.
116. Georgiew D. A., Kostow B. S. 1960. *Metoda prognozy mocy w systemach energetycznych*. Komisja Elektryfikacji Polskiej PAN. Warszawa, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
117. Geron A. 2018. *Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow - pojęcia, techniki i narzędzia służące do tworzenia inteligentnych systemów*. Wydawnictwo Helion/O'Reilly. Gliwice. 2018.

118. Glover F., Laguna M. 1997. *Tabu Search*. Springer Science+Business Media New York. New York 1997.
119. Goldberger A. S. 1972. *Maximum Likelihood Estimation of Regression Models Containing Unobservable Variables*. "International Economic Review". January. Pp. 1 - 15, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
120. Goldberger A. S. 1991. *A Course in Econometrics*. Harvard University Press. Boston, w: Maddala G. S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
121. Gorwar M., Harsha J. S. 2012. *Short Term Load Forecasting using Time Series Analysis: A case study for Karnataka, India*. International Journal of Engineering Science and Innovative Technology (IJESIT) Volume 1, Issue 2, November 2012. ResearchGate. January 2012. Uploaded on 24 October 2017. ISSN: 2319-5967.
122. Góra S. 1964. *Metoda prognozy obciążeń systemu elektroenergetycznego z zastosowaniem matematycznych maszyn cyfrowych*. Archiwum Elektrotechniki. N. 2/164, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo-Techniczne. Warszawa. 1971.
123. Góra S. 1964. *Prognoza obciążeń krajowego systemu elektroenergetycznego na matematycznej maszynie cyfrowej ZAM2*. Zeszyty Naukowe Pol. Gdańskiej. N. 53, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
124. Góra S. 1975. *Gospodarka elektroenergetyczna w przemyśle*. Państwowe Wydawnictwo Naukowe. Warszawa. 1975.
125. Griliches Z. 1974. *Errors in Variables and Other Unobservables*. "Econometrica". November. Pp. 971 - 998, w: Maddala G. S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
126. Grinstead C.M., Snell J. L. 2006. *Introduction to Probability*. Swarthmore College and Dartmouth College. American Mathematical Society.
127. Grus J. 2018. *Data science od podstaw - Analiza danych w Pythonie*. Wydawnictwo Helion/O'Reilly. Gliwice. 2018.
128. Gu X., Xiong B. 2018. *Analysis of Power User Behavior Based on Big Data Technology: A Review*. Wydawnictwo IEEE.
129. Guriewicz B. A. 1960. *Zagadnienie prognozy krzywych obciążeń w systemie elektroenergetycznym i w systemach połączonych*. Kom. Elektryfikacji Polski PAN. Warszawa, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
130. Guzik B. 2008. Wstęp do teorii prognozowania i symulacji. AE, Poznań, 2008. Str. 173-177.
131. Gwóźdź R., Czapaj R. 2020. *Wpływ rozwoju PV na KSE*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2020.
132. Hand D. J., Mannila H., Smyth P. 2001. *Principles of Data Mining*. Wydawnictwo MIT/Bradford Book.
133. Hao J., Gu H., Wang R., Deng M., Liu Y., Yang D., Lei J., Huang Z. 2018. *Short-term Power Load Forecasting for Larger Consumer based on TensorFlow Deep Learning Framework and Clustering-regression Model*. Wydawnictwo IEEE.
134. Harrison G. 2019. *NoSQL, NewSQL i BigData - Bazy danych następnej generacji*. Wydawnictwo Helion. Gliwice. 2019.
135. Hassan S., Khosravi A., Jaafar J. 2015. *Examining performance of aggregation algorithms for neural network-based electricity demand forecasting*. Electrical Power and Energy Systems 64 (2015) 1098 - 1105. Contents lists available at ScienceDirect. Electrical Power and Energy Systems. 0142 - 0615. 2014. Elsevier Ltd.
136. Hastie T., Tibshirani R., Friedman J. 2008. *Data Mining, Inference, and Prediction*. Stanford 2008. Springer Series in Statistics. The Elements of Statistical Learning (Second Edition).
137. Hausman J. A. 1978. *Specification Tests in Econometrics*. "Econometrica". Vol. 46. Pp. 1251 - 1271, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
138. Hayashi Y. 1993. *Long - Term Load Forecasting Using Improved Recurrent Neural Network*. Electrical Engineering In Japan, Vol. 113. November.

139. He W. 2014. *Deep Neural Network Based Load Forecast*. Computer Modelling & New Technologies 2014 18(3) 258 - 262. State Grid Energy Research Institute, State Grid Corporation of China. March 1st, 2014.
140. Hellwig Z. 1967. *Schemat budowy prognozy statystycznej metodą wag harmoniczných*. „Przegląd Statystyczny”. Z. 2. Str. 258.
141. Helt P., Parol M., Piotrowski P. 2000. *Metody sztucznej inteligencji w elektroenergetyce*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
142. Helt P., Parol M., Piotrowski P. 2012. *Metody sztucznej inteligencji - Przykłady zastosowań w elektroenergetyce*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
143. Hendry D.F. 1979. *Predictive Failure and Econometric Modelling in Macroeconomics: The Transactions Demand for Money*. w: Ormerod P. (red.) *Economic Modelling*. Heinmann. London, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
144. Hołubiec J. 1965. *Badania struktury zapotrzebowania mocy i energii elektrycznej w gospodarstwach domowych w miastach*. Energetyka. Z. 9. Str. 271-276, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
145. Hołubiec J. 1968. *Zastosowanie regresji wielokrotnej w elektroenergetyce*. Przegląd Elektrotechniczny. Z. 2. Str. 78 - 80, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo-Techniczne. Warszawa. 1971.
146. Hong T., Wang P. 2014. *Fuzzy Interaction Regression for Short Term Load Forecasting*. Hugo Steinhaus Center Wrocław University of Technology. University of North Carolina at Charlotte, USA, 2 SAS Institute, Cary, NC, USA. 13(1), 91-103.
147. Hsiao-Tien P. 2009. *Forecast of Electricity Consumption and Economic Growth in Taiwan by State Space Modeling*. Energy 34 (2009) 1779 - 1791. Contents lists available at ScienceDirect. Energy. 10 September 2009. 0360-5442/\$, 2009 Elsevier Ltd.
<http://www-stat.wharton.upenn.edu/~steele/Courses/956/Resource/YWSourceFiles/YW-Eshel.pdf>.
148. Hu L., Liu K. - Y., Lin Z., Diao Y., Sheng W. 2018. *An Abnormal State Detection Method for Power Distribution Network Based on Big Data Technology*. 2018 International Conference on Cyber - Enabled Distributed Computing and Knowledge Discovery. Wydawnictwo IEEE. China, Beijing.
149. Huang J., Niu L., Zhan J., Peng X., Bai J., Cheng S. 2014. *Technical Aspects and Case Study of Big Data based Condition Monitoring of Power Apparatuses*. Wydawnictwo IEEE.
150. Huang X., Huang A., Huang H., Ouyang W., Zhu Y. 2019. *Economic Operation Platform for Power Grid Company*. 2019 IEEE 4th International Conference on Cloud Computing and Big Data Analytics Wydawnictwo IEEE.
151. Instytut Meteorologii i Gospodarki Wodnej - Państwowy Instytut Badawczy. 2018. Witryna internetowa <https://www.imgw.pl/>.
152. Instrukcja Ruchu i Eksploatacji Sieci Przesyłowej. 2016. IRiESP - Bilansowanie systemu i zarządzanie ograniczeniami systemowymi. PSE S.A., Warszawa 2016 r.
153. Ishida T., Tamura S. 1994. *Daily Electric Load Forecasting Using Artificial Neural Network*. Electrical Engineering In Japan, Vol. 114. November.
154. Janicki M. 2017. *Temperature Correction Method for Pattern Similarity - Based Short - Term Electricity Demand Forecasting Models*. Czestochowa University of Technology, Faculty of Electrical Engineering. Przegląd Elektrotechniczny, ISSN 0033 - 2097, R. 93 NR 3/2017.
155. Jetcheva J. G., Majidpour M., Chen W. P. 2014. *Neural Network Model Ensembles for Building - Level Electricity Load Forecasts*. Energy and Buildings 84 (2014) 214-223. Contents lists available at ScienceDirect. 0378-7788/© 2014 Elsevier B.V. Fujitsu Laboratories of America, Sunnyvale, CA, USA. Energy and Buildings.
156. Jin L., Haosong L., Zhongping X., Ting W., Jia W., Dan Su. 2019. *Research on Wide-Area Distributed Power Quality Data Fusion Technology of Power Grid*. 2019 IEEE 4th International Conference on Cloud Computing and Big Data Analytics. Wydawnictwo IEEE.
157. Johannesen N. J., Kolhe M., Goodwin M. 2018. *Comparison of Regression Tools for Regional Electric Load Forecasting*. Wydawnictwo IEEE.
158. Kacprzyński B. 1974. *Planowanie eksperymentów - podstawy matematyczne*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1974.

159. Kamiński J. 2010. *Metody modelowania równowagi rynków energii elektrycznej*. Rynek Energii. Str. 127 - 136.
160. Kamiński J. 2011. *Power Generation And Capacity Planning Modules For Global Energy Sector Models*. Rynek Energii. Str. 113-118.
161. Kamiński J. 2011. *Założenia metodyczne do budowy modelu równowagi rynku energii elektrycznej dla warunków Polski*. Energetyka. Str. 10-16.
162. Kamiński J., Kaszyński P. 2011. *Wybrane problemy implementacji zapotrzebowania na moc w matematycznych modelach systemów energetycznych*. Polityka Energetyczna, 2011. Tom 14. Zeszyt 2.
163. Kamiński J., Kaszyński P., Malec M. 2015. *Representation of Power Demand in the Long-Run Energy System Models*. Energy System Modelling. January.
164. Kamiński S. 1961. *Metoda budowy perspektywicznych wykresów dobowego obciążenia systemu energetycznego*. Instytut Energetyki. N. 2206. Warszawa, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
165. Kandel A., Last M., Bunke H. 2001. *Data Mining and Computational Intelligence*. Studies in Fuzziness and Soft Computing. Springer-Verlag, Berlin Heidelberg GmbH.
166. Kasperski M. J. 2003. *Sztuczna Inteligencja - Droga do myślących maszyn*. Wydawnictwo Helion. Gliwice. 2003.
167. Keitsch K., Bruckner T. 2016. *SAWing on Short Term Load Forecasting Errors: Increasing the Accuracy with Self Adaptive Weighting*. 2016 IEEE Innovative Smart Grid Technologies - Asia (ISGT-Asia). Wydawnictwo IEEE. Melbourne, Australia, Nov 28 - Dec.
168. Kendall M. G., Buckland W. R. 1975. *Słownik terminów statystycznych* (Przekład: Marian Kanton). Państwowe Wydawnictwo Ekonomiczne. Warszawa. 1975.
169. Kendall, M. G. 1975. *Rank Correlation Methods* (4th Ed.). London: Griffin.
170. Kheirkhah A., Azadeh A., Saberi M., Azaron A., Shakouri H. 2013. *Improved Estimation of Electricity Demand Function by Using of Artificial Neural Network, Principal Component Analysis and Data Envelopment Analysis*. Computers & Industrial Engineering 64 (2013) 425 - 441. Contents lists available at SciVerse ScienceDirect. Computers & Industrial Engineering. 0360-8352/\$ - 2012 Elsevier Ltd. All rights reserved. 13 October.
171. Klóska R., Hundert M., Czyżycki R. 2007. *Wybrane zagadnienia z prognozowania*. Wydawnictwo Economicus, Szczecin.
172. Kocot H., Korab R., Owczarek R., Przygodzki M., Żmuda K. 2015. *Metody przeciwdziałania nieplanowemu przepływowi mocy w połączonym systemie elektroenergetycznym*. Prace naukowe Politechniki Śląskiej, Kwartalnik Elektryka, 2015, Wydanie 4. Str. 81 - 93.
173. Kocot H., Korab R., Żmuda K. 2009. *Planowanie pracy jednostek wytwórczych na rynku energii elektrycznej - przegląd stosowanych metod*. Prace naukowe Politechniki Śląskiej, Kwartalnik Elektryka, 2009. Str. 7 - 31.
174. Kolcun M., Holka L. 2002. *Daily Load Diagram Prediction of Eastern Slovakia*. Wydawnictwo Politechniki Częstochowskiej. VI Konferencja Naukowa Prognozowanie w Elektroenergetyce, Prognozowanie, Efektywność Energetyczna. Częstochowa - Złoty Potok, 18 - 20 Września.
175. Kollia L., Kollias S. 2018. *A Deep Learning Approach for Load Demand Forecasting of Power Systems*. Wydawnictwo IEEE.
176. Koopmans T. C. 1957. *Three Essays on the State of Economics Science*. McGraw-Hill. New York. Pp. 142 - 143, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
177. Kopecki K. 1958. *Analiza zmienności obciążeń systemów energetycznych w Polsce*. Zeszyty Naukowe Pol. Gdańskiej. N. 2, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
178. Kopecki K. i in. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne, Warszawa.
179. Kopecki K., Dobrzańska I. i inni. Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne, Warszawa.
180. Korab R. 2011. *Optymalizacja operatorstwa przesyłowego w krajowym systemie elektroenergetycznym*. Wydawnictwo Politechniki Śląskiej. 2011.

181. Korab R., Owczarek R. 2015. *Bezpieczeństwo międzynarodowego transportu energii elektrycznej w kontekście nieplanowych przepływów mocy*. Logistyka, Issue 4, 2015, CD2. Str. 4137 - 4143.
182. Korab R., Połomski M., Owczarek R. 2021. *Application of Particle Swarm Optimization for Optimal Setting of Phase Shifting Transformers to Minimize Unscheduled Active Power Flows*. Applied Soft Computing, Vol. 105, 2021. Pp. 107243.
183. Kot S. M., Jakubowski J., Sokołowski A. 2007. *Statystyka. Podręcznik dla studiów ekonomicznych*. StatSoft Polska Sp. z o.o., Centrum Doradztwa i Informacji Difin Sp. z o.o., Warszawa 2007.
184. Kozik Z., Malko J., Trybuła St. 1964. *Analiza zmienności szczytów krajowego systemu elektroenergetycznego*. Prace IASE. N. 1/1964, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
185. Krasker W. S. 1981. *The Role of Bounded Influence Estimation in Model Selection*. "Journal of Econometrics". Vol. 16, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN. Pp. 131-138.
186. Krókowski A., Malko J., Trybuła S. 1962. *Metody analizy prognozy zmienności obciążeń*. Komisja Elektryfikacji Polskiej PAN. Materiały i Studia. T. X. Z. 1-11. PWN. Łódź-Warszawa 1962, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
187. Ku T. I., Park W. K., Choi H. 2018. *Energy Peak Reduction Mechanism with Prediction of Demand and PV Generation on Big Data*. 2018 IEEE International Conference on Big Data and Smart Computing. Wydawnictwo IEEE.
188. Kubek P., Zdunek M., Anna Gorczyca-Goraj, Jacek Wasilewski, Czapaj R. 2020. *Uczestnictwo w imieniu PSE S.A. w pracach roboczych Komitetu Badań i Rozwoju RDIC ENTISO-E*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2020.
189. Kuczera F. 1960. *Prognoza przebiegów obciążenia w planowaniu rozwoju systemu elektroenergetycznego*. Komitet Elektryfikacji Polskiej PAN. Warszawa, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo-Techniczne. Warszawa. 1971.
190. Kufel T. 2015. *Rozwiązywanie problemów z wykorzystaniem programu GRETL*. Wydawnictwo Naukowe PWN. *Ekonometria*.
191. Kusy M. 2015. *Metody wizualizacji danych*. StatSoft Polska. Materiały kursowe StatSoft Polska. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. 21 października 2015.
192. Kvhasei M., Bijari M., Ardali G. A. R. 2009. *Improvement of Auto-Regressive Integrated Moving Average Models using Fuzzy Logic and Artificial Neural Networks (ANNs)*. Neurocomputing 72 (2009) 956-967. Contents lists available at ScienceDirect. Neurocomputing. 0925-2312/. 2008 Elsevier B. V. 20 May 2008. Department of Industrial Engineering, Isfahan University of Technology, Isfahan, Iran.
193. Lang J., Pascoe S., Thomson J., Woyak J., Rahimi K., Broadwater R. 2016. *Smart Grid Big Data: Automating Analysis of Distribution Systems*. Wydawnictwo IEEE.
194. Leamer E. E. 1978. *Specification Searches: Ad Hoc Inference with Non-Experimental Data*. Wiley. New York, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
195. Leszczyński J. 1978. *Problemy planowania i prognozowania*. Państwowe Wydawnictwo Ekonomiczne. Warszawa. 1978.
196. Li J., Song Z., Zhong Y., Zhang Z. 2017. *Short-Term Load Forecasting Based on Improved Extreme Learning Machine*. 2017 IEEE 2nd International Conference on Big Data Analysis.
197. Liao X., Cao N., Ma L., Kang X. 2019. *Research on Short-term Load Forecasting Using XGBoost Based on Similar Days*. 2019 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS). Wydawnictwo IEEE.
198. Lin Y., Luo H., Wang D., Guo H., Zhu K. 2017. *An Ensemble Model Based on Machine Learning Methods and Data Preprocessing for Short-Term Electric Load Forecasting*. Energies 2017, 10, 1186; www.mdpi.com/journal/energies. MDPI.
199. Liu N., Babushkin V., Afshari A. 2013. *Short-Term Forecasting of Temperature Driven Electricity Load Using Time Series and Neural Network Model*. Journal of Clean Energy Technologies, Vol. 2, No. 4, October 2014. Manuscript received September 29, 2013; revised December 20.

200. Liu N., Ma L., Liu X., Yu H., Tan H., Zhao Y., Guodong Lv. 2017. *Research on Key Issues of Data Integration Technology in Electric Power System in Big Data Environment*. 2017 9th IEEE International Conference on Communication Software and Networks. Wydawnictwo IEEE.
201. Liu T. C. 1960. *Under-Identification, Structural Estimation, and Forecasting*. "Econometrica". Vol. 28. Pp. 855 - 865, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
202. Liu Z., Zou Y. 2018. *Research on Distribution Network Operation and Control Technology Based on Big Data Analysis*. 2018 China International Conference on Electricity Distribution. Wydawnictwo IEEE. Tianjin, 17 - 19 Sep.
203. Lu Y., Zhang T., Zeng Z., Loo J. 2016. *An Improved RBF Neural Network for Short-Term Load Forecast in Smart Grids*. Wydawnictwo IEEE.
204. Lubośny Z. 2009. *Farmy wiatrowe w systemie elektroenergetycznym*. Wydawnictwa Naukowo - Techniczne. Warszawa. 2009.
205. Lucas R. E, Rapping L. A. 1969. *Price Expectations and the Philips Curve*. "The American Economic Review". Vol. 59. Pp. 342-350, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
206. Lula P. 2002. *Sztuczne sieci neuronowe jako narzędzie analiz typu Data Mining*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
207. Lula P. 2002. *Sztuczne sieci neuronowe jako narzędzie analiz typu Data Mining*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
208. Łapczyński M., Demski T. 2018. *Data Mining - metody predykcyjne*. Materiały kursowe StatSoft Polska. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. 03 - 04 grudnia.
209. Łapczyński M., Lula P., Demski T. 2006. *Data Mining IIb - modele i metody*. Materiały kursowe StatSoft Polska. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. 29 - 30 listopada - 1 grudnia.
210. Łyp J. 1995. *Analiza zmienności obciążeń w systemach lokalnych*. VII Międzynarodowa Konferencja Naukowa Aktualne Problemy w Elektroenergetyce APE'95. Gdańsk - Jurata. 12-14 czerwca.
211. Łyp J. 2000. *Metodyka analizy i prognozy obciążeń elektroenergetycznych systemów lokalnych - Rozprawa doktorska*. Politechnika Częstochowska.
212. Łyp J. 2001. *Prognozy krótkoterminowe przebiegów obciążeń dobowych systemów lokalnych dla potrzeb rynku energii*. Materiały Konferencji Naukowej "Aktualne Problemy w Elektroenergetyce APE'01. Str. 101 - 107.
213. Łyp J. 2003. *Krótkoterminowe prognozy obciążeń systemów lokalnych dla potrzeb rynków energii*. XI Międzynarodowa Konferencja Naukowa Aktualne Problemy w Elektroenergetyce APE'03, Vol. III, Jurata 2003. Str. 77 - 82.
214. Łyp J. 2013. *Modelowanie rocznej zmienności obciążeń KSE z uwzględnieniem efektu eskalacji użytkownika urządzeń wentylacyjno - klimatyzacyjnych*. (Prognozowanie w elektroenergetyce 2013). Wydawnictwo Politechniki Częstochowskiej. Politechnika Częstochowska. Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce PE'13. Przegląd Elektrotechniczny.
215. Łyp J. 2016. *Problematyka prognozowania zapotrzebowania na letnią moc szczytową krajowego systemu elektroenergetycznego*. XIII Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce, Podlesice 6 - 8 kwietnia.
216. Machowski J. 2007. *Regulacja i stabilność systemu elektroenergetycznego*. Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa. 2007.
217. Maddala G. S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
218. Magnano L., Boland J. W. 2007. *Generation of Synthetic Sequences of Electricity Demand: Application in South Australia*. Energy 32 (2007) 2230-2243. ScienceDirect. Available online at www.sciencedirect.com. Centre for Industrial and Applied Mathematics, University of South Australia. 0360 - 5442. 2007 Elsevier Ltd.
219. Makino K., Shimada T. 1995. *Daily Peak Electric Load Forecasting Using an Artificial Neural Network and an Improvement Method for Reducing the Forecasting Errors*. Electrical Engineering In Japan, Vol. 114. January.
220. Malko J. 1964. *Analiza i programowanie zmienności obciążeń krajowych systemów elektroenergetycznych*. Dysertacja. Wrocław, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971.

- Analiza i prognoza obciążeń elektroenergetycznych.* Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
221. Malko J. 1966. *Analiza i prognozowanie zmienności obciążeń krajowych systemów energetycznych.* Komitet Energetyki PAN. Sympozjum w Jabłonie. 20-21 maja, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych.* Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
 222. Malko J. 1995. *Wybrane zagadnienia prognozowania w elektroenergetyce: Prognozowanie zapotrzebowania energii i mocy elektrycznej.* Oficyna Wydawnicza Politechniki Wrocławskiej.
 223. Malko J. 1997. *Sztuczne sieci neuronowe - nowe narzędzie prognozowania elektroenergetycznego.* Materiały Konferencyjne Aktualne Problemy w Elektroenergetyce APE'97. Gdańsk.
 224. Malska W., Wachta H. 2015. Wykorzystanie modelu ARIMA do analizy szeregu czasowego. Zeszyty Naukowe Politechniki Rzeszowskiej 292, Elektrotechnika 34. RUTJEE, z. 34 (3/2015), lipiec - wrzesień 2015. Str. 23 - 30.
 225. Marchel P., Paska J. 2016. *Wzrost zapotrzebowania na energię elektryczną w lecie a niezawodność zasilania odbiorców.* Rynek Energii Elektrycznej - Bezpieczeństwo energetyczne Polski. Wydawnictwo Politechniki Lubelskiej. Lublin. Str. 74 - 78.
 226. Mari J. -F., Schott R. 2001. *Probabilistic and Statistical Methods in Computer Science.* Springer Science+Business Media New York, New York.
 227. Masters T. 1996. *Sieci Neuronowe w Praktyce (Programowanie w języku C++).* WNT. Warszawa.
 228. McDowall D., McCleary R., Meidinger E. E., Hay R.A. 1980. *Interrupted Time Series Analysis.* Beverly Hills, CA: Sage Publications.
 229. Mielczarski W. 2000. *Rynki energii elektrycznej - Wybrane aspekty techniczne i ekonomiczne.* Agencja Rynku Energii S.A. Warszawa. 2000.
 230. Mielczarski W. 2000. *Rynki energii elektrycznej: wybrane aspekty techniczne i ekonomiczne.* Agencja Rynku Energii. Warszawa.
 231. Mielczarski W. 2002. *Koszty Bilansowania i ograniczeń na rynku energii elektrycznej.* Rynek Energii, Nr 4(41).
 232. Mizon G. E. 1977. *Model Selection Procedures* w: Artis M.J., Nobay A.R. (red.) *Studies in Current Econometric Analysis.* Basil Blackwell. Oxford, w: Maddala G.S. 2008. *Ekonometria.* Wydawnictwo Naukowe PWN.
 233. Mu Q., Wu Y., Pan X., Huang L. 2010. *Short-term Load Forecasting Using Improved Similar Days Method.* Wydawnictwo IEEE.
 234. Nadtoka I. I., Al-Zihery Balasim M. 2015. *Forecasting of Electricity Consumption of the Power System, With Due Account of Air Temperature and Natural Illumination, Based on Support Vector Machine and Particle Swarm.* Available online at www.sciencedirect.com. Procedia Engineering 129 (2015) 657 - 663. International Conference on Industrial Engineering (ICIE-2015). ScienceDirect. 1877-7058 © 2015 Published by Elsevier Ltd.
 235. Narayan A., Hipel K.W. 2017. *Long Short Term Memory Networks for Short-Term Electric Load Forecasting.* IEEE International Conference on Systems, Man, and Cybernetics (SMC), Banff Center, Banff, Canada, October 5 - 8, 2017. 978 - 1 - 5386 - 1644 - 4/17/\$31.00 ©2017 IEEE.
 236. Nazarko J., Chraślowska J., Rybaczuk M. 2004. *Zastosowanie wielosezonowego modelu ARIMA w prognozowaniu obciążeń mocą elektryczną.* Politechnika Białostocka. Prace Naukowe Akademii Ekonomicznej we Wrocławiu. Nr 1022 Taksonomia 11, Klasyfikacja i analiza danych - teoria i zastosowania.
 237. Nęcka K. 2013. *Wpływ wstępnego przetwarzania danych na jakość krótkoterminowych prognoz zapotrzebowania na energię elektryczną.* Inżynieria Rolnicza. Agricultural Engineering. Z. 3(145) T.1. Str. 291 - 299.
 238. Nowicka-Zagrajek J., Weron R. 2002. *Modeling Electricity Loads in California: ARMA Models With Hyperbolic Noise.* Hugo Steinhaus Center Wrocław University of Technology. Research partially supported by KBN Grant PBZ - KBN 016/P03/99. Revised version, May 2002. Institute of Mathematics, Wrocław University of Technology, Poland.
 239. Nowicka-Zagrajek J., Weron R. 2002. *Modeling Electricity Loads in California: ARMA Models with Hyperbolic Noise.* Signal Processing 82 (2002) 1903 - 1915. 0165 - 1684/02/\$ - 2002 Elsevier Science B. V. PII: S 0165-1684(02)00318 - 3. 8 May.

240. Nowotarski J., Liu B., Weron R., Hong T. 2015. *Improving Short Term Load Forecast Accuracy via Combining Sister Forecasts*. Hugo Steinhaus Center Wrocław University of Technology. July, 2015. Department of Operations Research, Wrocław University of Technology, Poland, Energy Production and Infrastructure Center, University of North Carolina at Charlotte, USA.
241. Osowski S. 1996. *Sieci Neuronowe*. Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa.
242. Paska J. 2007. *Ekonomika w Elektroenergetyce*. Wydawnictwo OWPW. Warszawa.
243. Pasztyła A. 2006. *Data Mining IIa - Metody bez nauczyciela*. Materiały kursowe StatSoft Polska. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. 29 - 30 marca.
244. Pasztyła A. 2008. *Statystyczne Metody Prognozowania Popytu na Rynkach Energii Elektrycznej*. Uniwersytet Ekonomiczny w Krakowie, Wydział Zarządzania, Katedra Statystyki. Rozprawa doktorska. Kraków.
245. Pawłęga A. 2011. *Rachunek ekonomiczny w elektroenergetyce - Materiały do wykładu i ćwiczeń*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
246. Pawłowski Z. 1973. *Prognozy ekonometryczne*. PWN, Warszawa. Str. 14-15.
247. Pawłowski Z. 1974. *Teoria prognozy ekonometrycznej w gospodarce socjalistycznej*. PWN, wyd. 2. Warszawa. Str. 15.
248. Pei Z., Wu X., Wang X., Bi S. 2015. *Short - Term Load Forecasting Based on Big Data Technologies*. CSEE Journal of Power And Energy Systems, Vol. 1, No. 3, Wydawnictwo IEEE.
249. Piotrowski P. 2001. *Krótkoterminowe prognozy zapotrzebowania na energię elektryczną dla spółek dystrybucyjnych w warunkach rynku energii przy wykorzystaniu technik sztucznej inteligencji*. X Międzynarodowa Konferencja Naukowa pt. Aktualne problemy w Elektroenergetyce (APE-01), Jurata, 6 - 8 czerwiec 2001, t. III. Str. 117 - 124.
250. Piotrowski P. 2007. *Prognozowanie krótkoterminowe godzinowych obciążeń w spółce dystrybucyjnej z wykorzystaniem sieci neuronowych - analiza wpływu doboru i przetworzenia danych na jakość prognoz*. Przegląd Elektrotechniczny, R. 83, Nr 7-8/2007. Str. 40 - 43.
251. Piotrowski P. 2011. *Analiza skuteczności wybranych algorytmów uczących sieci neuronowych typu MLP w zadaniu prognozowania krótkoterminowego zapotrzebowania na energię elektryczną na potrzeby spółek dystrybucyjnych*. Śląskie Wiadomości Elektryczne, 1/2011. Str. 18 - 24.
252. Piotrowski P. 2013. *Prognozowanie w elektroenergetyce w różnych horyzontach czasowych. Rozprawa habilitacyjna*. Politechnika Warszawska, Instytut Elektroenergetyki, Prace Naukowe Elektryka z. 144. Warszawa 2013. Oficyna Wydawnicza Politechniki Warszawskiej.
253. Piotrowski P., Górski M. 1999. *Ekonomiczne aspekty krótkoterminowego prognozowania zużycia energii elektrycznej wybranych grup odbiorców przy wykorzystaniu techniki sieci neuronowych*. VIII Międzynarodowa Konferencja Naukowa pt. Aktualne problemy w Elektroenergetyce (APE - 99), Jurata, 9 - 11 czerwiec.
254. Polskie Sieci Elektroenergetyczne S.A. - *Biuro Komunikacji, Konstancin-Jeziorna. 2015. Analiza Energetycznych FAE dotyczących niedoboru mocy w polskim systemie elektroenergetycznym w sierpniu 2015 r. 17 września 2015. Komentarz PSE do publikacji Forum*. Warszawa. 2015.
255. Polskie Sieci Elektroenergetyczne S.A. 2020. *Instrukcja Ruchu i Eksploatacji Sieci Przesyłowej: Bilansowanie systemu i zarządzanie ograniczeniami systemowymi (2010 z późniejszymi zmianami)*. Warszawa. 2020.
256. Polskie Sieci Elektroenergetyczne S.A. 2020. Witryna internetowa <https://www.pse.pl/home>. Warszawa.
257. Popczyk J., Żmuda K. 1991. *Sieci elektroenergetyczne - Ocena stanu i optymalizacja według podejścia probabilistycznego*. Wydawnictwo Politechniki Śląskiej. Gliwice. 1991.
258. Popławski T. 2009. *Methods of Analysis and Forecast of Power Engineering Load Variation in the Conditions of Energy Market Transformation*. Serie Monographs No 163. Wydawnictwo Politechniki Częstochowskiej. Częstochowa.
259. Popławski T., Dąsał K., Dudek G., Łyp J., Sowiński J., Starczynowska E. 2010. *Opracowanie i weryfikacja modeli do prognozowania zapotrzebowania na moc elektryczną w krajowym systemie elektroenergetycznym (KSE) dla potrzeb opracowania w PSE Operator SA planów koordynacyjnych*. Centrum Zastosowań Zaawansowanych Technologii Sp. z o.o., Warszawa (niepubl.). 2010.
260. Popper K. F. 1959. *The Logic of Scientific Discovery*. Hutchinson. Londyn. Pp. 42.

261. *Poradnik Inżyniera Elektryka Tom 1.* 1996. Wydanie drugie częściowo zmienione. Warszawa, 1996. Wydawnictwa Naukowo-Techniczne.
262. *Poradnik Inżyniera Elektryka Tom 2.* 1997. Wydanie drugie częściowo zmienione. Warszawa, 1997. Wydawnictwa Naukowo-Techniczne.
263. *Poradnik Inżyniera Elektryka Tom 3.* 1997. Wydanie drugie częściowo zmienione. Warszawa, 1997. Wydawnictwa Naukowo-Techniczne.
264. Przygodzki M., Gwóźdź R., Chmurski P. 2016. *Modelowanie zapotrzebowania dla potrzeb długoterminowego planowania rozwoju.* Wydawnictwo Politechniki Lubelskiej. Lublin. Str. 97-107.
265. Qing L., Boyu Z., Qinqian Li. 2017. *Impact of Big Data on Electric-power Industry.* 2017 IEEE 2nd International Conference on Big Data Analysis. Wydawnictwo IEEE.
266. Rabiej M. 2018. *Analizy statystyczne z programami Statistica i Excel.* Wydawnictwo Helion. Gliwice. 2018.
267. Rana M., Koprinska I. 2016. *Forecasting Electricity Load with Advanced Wavelet Neural Networks.* Neurocomputing 182 (2016) 118-132. Contents lists available at ScienceDirect. Neurocomputing, 14 December 2015. 0925 - 2312/& 2015 Elsevier B. V.
268. Ratner B. 2003. *Statistical Modeling and Analysis for Database Marketing: Effective Techniques for Mining Big Data.* Wydawnictwo CRC Press.
269. Redakcja Encyklopedii, Leksykonów i Słowników WNT. 2004. *Angielsko - polski słownik elektryczny (Słownik podręczny).* Wydawnictwa Naukowo - Techniczne. Warszawa. 2004.
270. Rodriguez-Fernandez V., Trzcionkowska, A., Gonzalez-Pardo A., Brzychczy E., Nalepa G. J., Camacho D. 2021. *Conformance Checking for Time Series - Aware Processes.* IEEE Transactions on Industrial Informatics, vol. 17, no. 2, art. no. 9018187/. Pp. 871 - 881.
271. Russo M., Ferrari A. 2016. *Kompletny przewodnik po DAX - Analiza biznesowa przy użyciu Microsoft Excel, SQL Server Analysis Services i Power BI.* Wydawnictwo APN PROMISE SA/Microsoft. Warszawa. 2016.
272. Rutkowska D. 2002. *Neuro - Fuzzy Architectures and Hybrid Learning.* Studies in Fuzziness and Soft Computing. Springer - Verlag, Berlin Heidelberg GmbH.
273. Rutkowski L. 2004. *Flexible Neuro-Fuzzy Systems - Structures, Learning and Performance Evaluation.* Kluwer Academic Publishers, New York, Boston, Dordrecht, London, Moscow. The Kluwer International Series in Engineering and Computer Science. Boston.
274. Saber A. Y., Alam R. 2017. *Short Term Load Forecasting using Multiple Linear Regression for Big Data.* Wydawnictwo IEEE.
275. Sagioglu S., Sinanc D. 2013. *Big Data: A Review.* Wydawnictwo IEEE.
276. Samul K., Korab R., Cetnarski R., Wawrzyniak K., Kadłubowska A. 2018-2019. *Analiza możliwości i metod wykorzystywanych w procesie przewidywania potencjalnych awarii elementów infrastruktury sieci przesyłowej.* NCBJ/NCAE, Warszawa (niepubl. - na zlecenie PSE S.A.). 2018-2019.
277. Sawyer K. R. 1980. *The Theory of Econometric Model Selection.* Australian National University. Camberra (niepublikowana rozprawa doktorska), w: Maddala G.S. 2008. *Ekonometria.* Wydawnictwo Naukowe PWN.
278. Sevlian R.A., Rajagopal R. 2014. *A Model For The Effect of Aggregation on Short Term Load Forecasting.* 978-1-4799-6415-4/14/\$31.00 ©2014 IEEE. www.web.stanford.edu. Department of Electrical Engineering, Stanford University, Department of Civil and Environmental Engineering, Stanford University.
279. Shady S. R., Haitham A. -R., Amira M. 2016. *Big Data, Better Energy Management and Control Decisions for Distribution Systems in Smart Grid.* 2016 IEEE International Conference on Big Data (Big Data). Wydawnictwo IEEE.
280. Shi H., Xu M., Li R. 2018. *Deep Learning for Household Load Forecasting - A Novel Pooling Deep RNN.* IEEE Transactions on Smart Grid, Vol. 9, No. 5. Wydawnictwo IEEE. September.
281. Siwek K., Osowski S. 2009. *Prognozowanie obciążeń 24 - godzinnych w systemie elektroenergetycznym z użyciem zespołu sieci neuronowych.* Przegląd Elektrotechniczny (Electrical Review), ISSN 0033 - 2097, R. 85 NR 8/2009.
282. Skorupski W. 1990. *Zastosowanie modeli autoregresji dla bieżącej predykcji krótkoterminowej zapotrzebowania mocy w systemie elektroenergetycznym.* Prace Nauk. i Progn., nr 1-2.

283. Smirnow N. W., Dunin-Borkowski I. 1960. *Krótki kurs statystyki matematycznej dla zastosowań technicznych*. Ucz. Pol. Poznańskiej, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
284. Smoluk A. 1993. *Matematyka, nauka, ekonomia*. Wydawnictwo Akademii Ekonomicznej we Wrocławiu. Wrocław. Str. 83.
285. Sobczyk M. 2006. *Statystyka - aspekty praktyczne i teoretyczne*. Wydawnictwo Uniwersytetu Marii Curie-Skłodowskiej. Lublin.
286. Sokołowski A. 2003. *Prognozowanie finansowych szeregów czasowych*. StatSoft Polska Sp. z o.o.
287. Sokołowski A. 2004. *O niewłaściwym stosowaniu metod statystycznych*. Akademia Ekonomiczna w Krakowie, Katedra Statystyki; StatSoft Polska Sp. z o.o. StatSoft Polska, 2004.
288. Sokołowski A. 2005. *Data Mining - Automat czy metoda naukowa?* StatSoft Polska, Akademia Ekonomiczna w Krakowie, Katedra Statystyki, Kraków.
289. Sokołowski A. 2010. *Dlaczego warto znać metody statystyczne i Data Mining*. Wydawnictwo StatSoft Polska Sp. z o.o., Kraków.
290. Sokołowski A. 2018. *Analizy wielowymiarowe*. Materiały kursowe StatSoft Polska. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. 24 - 25 maja.
291. Sokołowski A., Paszyła A. 2003. *Data Mining w prognozowaniu zapotrzebowania na nośniki energii*. Wydawnictwo StatSoft Polska Sp. z o.o., Kraków.
292. Song M., Jia L. 2018. *Big Data Mining Method of Thermal Power Based on Spark and Optimization Guidance*. 2018 IEEE 7th Data Driven Control and Learning Systems Conference, Wydawnictwo IEEE. Enshi, Hubei Province, China. May 25 - 27.
293. Sousa J.C., Neves LP., Jorge H.M. 2012. *Assessing the relevance of load profiling information in electrical load forecasting based on neural network Models*. Electrical Power and Energy Systems 40 (2012) 85-93. Contents lists available at SciVerse ScienceDirect. Electrical Power and Energy Systems. 0142-0615/\$ - 2012 Elsevier Ltd.
294. Sowiński J. 2019. *Forecasting of electricity demand in the region*. E3S Web of Conferences, Vol. 84. Wydawnictwo EDP Sciences. 2019.
295. Sowiński J. 2019. *Temperatura powietrza jako dodatkowa zmienna egzogeniczna w krótkoterminowym prognozowaniu modelem ANFIS obciążeń w podsystemie elektroenergetycznym*. Przegląd Elektrotechniczny, R. 97 NR 1/2021.
296. Sowiński J., Szydłowski M. 2017. *Forecast of Electricity Supply Using Adaptive Neuro - Fuzzy Inference System*. Rusek R., Gono R., 18th International Scientific Conference on Electric Power Engineering, IEEE New York. 2017.
297. Stanisz A. 2006. *Przystępny kurs statystyki z zastosowaniem STATISTICA PL na przykładach z medycyny - Tom 1 - Statystyki podstawowe*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
298. Stanisz A. 2006. *Przystępny kurs statystyki z zastosowaniem STATISTICA PL na przykładach z medycyny - Tom 2 - Modele liniowe i nieliniowe*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
299. Stanisz A. 2006. *Przystępny kurs statystyki z zastosowaniem STATISTICA PL na przykładach z medycyny - Tom 3 - Analizy wielowymiarowe*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
300. Stanisz A. 2016. *Modele regresji logistycznej - Zastosowania w medycynie, naukach przyrodniczych i społecznych*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
301. StatSoft Polska. 2000. *Zastosowania metod statystycznych w badaniach naukowych I*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
302. StatSoft Polska. 2003. *Zastosowania metod statystycznych w badaniach naukowych II*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
303. StatSoft Polska. 2006. *Statystyka i Data Mining w badaniach naukowych*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
304. StatSoft Polska. 2008. *Praktyczne wykorzystanie analizy danych i Data Mining*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. Str. 29.
305. StatSoft Polska. 2008. *STATISTICA – Przewodnik*. Wydawnictwo StatSoft Polska Sp. z o.o., Kraków.

306. StatSoft Polska. 2008. *Zastosowania metod statystycznych w badaniach naukowych III*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
307. StatSoft Polska. 2012. *Zastosowania metod statystycznych w badaniach naukowych IV*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
308. StatSoft Polska. 2014. *Zastosowania statystyki i Data Mining w badaniach naukowych i innowacyjnych*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
309. StatSoft Polska. 2016. *Zastosowania metod statystycznych w badaniach naukowych V*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
310. StatSoft Polska. 2016. *Zastosowania statystyki i Data Mining w badaniach naukowych 2016*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
311. StatSoft Polska. 2017. *XXI Konferencja Zastosowania statystyki i Data Mining w badaniach naukowych*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
312. StatSoft Polska. 2020. *Internetowy podręcznik statystyki*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. <https://www.statsoft.pl/textbook/stathome.html>.
313. Stigler G. J. 1954. *The Early History of Empirical Studies of Consumer Behavior*. "The Journal of Political Economy" (przedruk: Stigler G.J [1965] *Essays in the History of Economics*, University of Chicago Press, Chicago).
314. Szewc B. 2005. *Angielsko - polski i polsko - angielski słownik terminów, pojęć i zwrotów z dziedziny elektroenergetyki*. Wydawnictwo Politechniki Śląskiej. Gliwice.
315. Szkutnik J. (red.) 2012. *Wybrane aspekty techniczne eksploatacji sieci rozdzielczych (Monografia)*. Wydawnictwo Politechniki Częstochowskiej, Częstochowa, 2012, r. 3.
316. Szkutnik J. 2020. *Nowe możliwości zmniejszenia strat energii elektrycznej w oparciu o sieci hybrydowe*. IX Konferencja Naukowo - Techniczna „Straty energii elektrycznej w sieciach elektroenergetycznych”, Naęczów 31 marca - 1 kwietnia / 9 - 10 grudnia 2020 r. Sl. 1 - 18.
317. Szmit A. 2008. *Prognozowanie zapotrzebowania na energię elektryczną. Studium empiryczne dla regionu łódzkiego*. Politechnika Łódzka. Wydział Organizacji i Zarządzania.
318. Szpyrka M., Brzychczy E., Napieraj A., Korski J., Nalepa G.J. 2020. *Conformance Checking of a Longwall Shearer Operation Based on Low - Level Events*. *Energies*, Vol. 13, Iss. 24, Art. No. 6630. Pp. 1 - 18.
319. Śmiech S. 2018. *Prognozowanie i analiza szeregów czasowych*. Materiały kursowe StatSoft Polska. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. 08 - 09 listopada.
320. Tadeusiewicz R. 1991. *Podstawy Biocybernetyki*. PWN. Warszawa.
321. Tadeusiewicz R. 1998. *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*. Akademicka Oficyna Wydawnicza PLJ. Warszawa.
322. Tadeusiewicz R. 2006. *Data Mining jako szansa na relatywnie tanie dokonywanie odkryć naukowych poprzez przekopywanie pozornie całkowicie wyeksploatowanych danych empirycznych*. StatSoft Polska, Akademia Górniczo - Hutnicza, Laboratorium Biocybernetyki, Kraków 2006.
323. Theodoridis S. 2015. Chapter 1. *Probability and Stochastic Processes. Machine Learning: A Bayesian and Optimization Perspective*. Academic Press. Pp. 9 - 51.
324. Tomasiak G., Przygodzki M., Gwóźdź R., Czapaj R. 2005. *Analiza porównawcza systemów SCADA/EMS dostępnych na rynku europejskim*. EPC Consulting, Warszawa (niepubl. - na zlecenie PSE Operator SA). 2005.
325. Trajdos T. 1974. *Matematyka dla inżynierów*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1974.
326. Turczak R., Przygodzki M., Czapaj R. 2013. *Opracowanie analizy wpływu źródeł fotowoltaicznych na warunki bilansowania Krajowego Systemu Elektroenergetycznego*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2013.
327. Turczak R., Przygodzki M., Czapaj R. 2013. *Opracowanie wytycznych do wykonywania ekspertyz wpływu na KSE przyłączania źródeł fotowoltaicznych do sieci przesyłowej oraz sieci zamkniętej o napięciu 110 kV Zadanie 1 - Zestawienie wymagań przyłączeniowych innych OSP*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2013.
328. Turczak R., Suszek A., Czapaj R. 2014-2015. *Analiza bezpieczeństwa pracy Krajowego Systemu Elektroenergetycznego w układzie planowanym na okres letni 2017 oraz na okres zimowy 2017/2018 - Sieć 400 kV i 220 kV z uwzględnieniem sieci 110 kV*. PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2014-2015.

329. Turczak R., Suszek A., Czapaj R. 2015. *Analiza bezpieczeństwa pracy Krajowego Systemu Elektroenergetycznego w układzie planowanym na okres letni 2017 oraz na okres zimowy 2017/2018 - Sieć 400 kV i 220 kV z uwzględnieniem sieci 110 kV* (Rozdział 7). PSE Innowacje Sp. z o.o., Warszawa (niepubl. - na zlecenie PSE S.A.). 2015.
330. Upadhaya D., Thakur R. Singh N. K. 2019. *A Systematic review on the Methods of Short Term Load Forecasting*. Conference: 2019 2nd International Conference on Power Energy, Environment and Intelligent Control (PEEIC).
331. Vatra D. F., Poida D. A., Stanescu D.C. 2007. *Data System for The Monitoring of Power Quality in The Transmission Substations Supplying Big Consumers*. Wydawnictwo IEEE.
332. Vijaya T., Vasirani M., Humeau S., Aberer K. 2015. *Cluster-Based Aggregate Forecasting for Residential Electricity Demand using Smart Meter Data*. 2015 IEEE International Conference on Big Data (Big Data). Wydawnictwo IEEE.
333. Vouros G.A., Panayiotopoulos T. (Eds.). 2004. *Methods and Applications of Artificial Intelligence*. Third Hellenic Conference on AI, SETN 2004 Samos, Greece, May 5 - 8, 2004, Proceedings. Springer-Verlag Berlin, Heidelberg, New York, New York.
334. Walker G. 1931. *On Periodicity in Series of Related Terms*. Proceedings of the Royal Society of London. Ser. A, Vol. 131. Pp. 518 - 532.
335. Wang J. 2011. *Method of Short-Term Load Forecasting Based on Bayesian Theorem*. 2011 International Conference on Mechatronic Science, Electric Engineering and Computer. Wydawnictwo IEEE.
336. Wang P., Liu B., Hong T. 2016. *Electric Load Forecasting with Recency Effect: A Big Data Approach*. International Journal of Forecasting (2016). Hugo Steinhaus Center Wrocław University of Technology. SAS - R&D, Cary, NC, USA; Energy Production and Infrastructure Center, University of North Carolina at Charlotte, USA.
337. Wang X. Z., Zhou J., Huang J. L., Bi X.L., Ge Z.Q. 2015. *A Multilevel Deep Learning Method for Big Data Analysis and Emergency Management of Power System*. Wydawnictwo IEEE.
338. Wang X., Zhao T., Liu H., He R. 2019. *Power Consumption Predicting and Anomaly Detection Based on Long Short - Term Memory Neural Network*. 2019 IEEE 4th International Conference on Cloud Computing and Big Data Analytics. Wydawnictwo IEEE.
339. Wang Y. F., Deng M. H., Bao Y. K., Zhang H., Chen J. Y., Qian J., Guo C.X. 2014. *Power System Disaster-Mitigating Dispatch Platform Based on Big Data*. 2014 International Conference on Power System Technology (POWERCON 2014 - China, Chengdu). Wydawnictwo IEEE.
340. Wang Y., Bielicki J.M. 2017. *Acclimation and the Response of Hourly Electricity Loads to Meteorological Variables*. Energy 142 (2018) 473e485. Contents lists available at ScienceDirect. Energy. 0360 - 5442/© 2017 Elsevier Ltd. 12 October.
341. Wang Y., Liu L., Pang X., Fan E. 2018. *Load Forecasting Based on Improved K-means Clustering Algorithm*. 2018 China International Conference on Electricity Distribution. Wydawnictwo IEEE. Tianjin, 17 - 19 Sep.
342. Wasilewski J. 2013. *Zastosowanie modeli klasy ARX do krótkoterminowego prognozowania produkcji energii elektrycznej w mikroelektrowniach wiatrowych*. (Prognozowanie w elektroenergetyce 2013). Wydawnictwo Politechniki Częstochowskiej. Politechnika Częstochowska. Międzynarodowa Konferencja Naukowa Prognozowanie w Elektroenergetyce. Przegląd Elektrotechniczny.
343. Wątroba J. 2002. *Przykład rozwiązania zagadnienia predykcyjnego za pomocą technik Data Mining*. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków.
344. Wątroba J. 2006. *Wątroba J. Od surowych danych do profesjonalnego raportu - przykład kompletnej analizy danych medycznych (materiał: Zastosowania statystyki i Data Mining)*. Wydawnictwo StatSoft Polska Sp. z o.o., Kraków.
345. Wątroba J. 2011. *Prosto o dopasowaniu prostych, czyli analiza regresji liniowej w praktyce*. Wydawnictwo StatSoft Polska Sp. z o.o., Kraków.
346. Wątroba J., Sokołowski A., Migut G. 2017. *Prognozowanie i analiza danych w energetyce*. Materiały kursowe StatSoft Polska. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. 28 - 31 marca.
347. Wątroba J., Sokołowski A., Wójtowicz P. 2003. *Prognozowanie i analiza danych w energetyce*. Materiały kursowe StatSoft Polska. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. 13 - 15 maja.

348. Weiss S.M., Indurkha N. 1998. *Predictive Data Mining - A practical Guide*. Morgan Kaufmann Publishers, Inc.
349. Welfe W. (red.) 1977: *Ekonometryczne modele rynku, tom I: Metody ekonometryczne*. PWE Warszawa, str.82, w: Maddala G. S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
350. Wieruchoń S., Kłopotek M. 2015. *Algorytmy analizy skupień*. Wydawnictwo WNT, Warszawa.
351. Wilczyński A. 2011. *Referat generalny do referatów podsekcji III.1. prognozowanie, planowanie i problemy rozwoju*. Politechnika Wrocławska. Konferencja Naukowa Aktualne Problemy w Elektroenergetyce, Jurata, 8 - 10 czerwca.
352. Williams J. W., Aggour K. S., Interrante J., McHugh J., Pool E. 2014. *Bridging High Velocity and High Volume Industrial Big Data Through Distributed In - Memory Storage & Analytics*. 2014 IEEE International Conference on Big Data. Wydawnictwo IEEE.
353. Winkler W., Wiszniewski A. 2004. *Automatyka zabezpieczeniowa w systemach elektroenergetycznych*. Wydawnictwo Naukowo - Techniczne. Warszawa. 2004.
354. Wiśniewski Z. 1966. *Rachunek prawdopodobieństwa w planowaniu elektroenergetycznym linii przesyłowych*. Zeszyty Naukowe Pol. Łódzkiej. Elektryka N. 18. Łódź, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
355. Wiśniewski Z. 1967. *Prawdopodobieństwo prognozy obciążenia układu elektroenergetycznego*. Zeszyty Naukowe Pol. Łódzkiej. Elektryka N. 22. Łódź, w: Dobrzańska I. (pod red.) Praca zbiorowa. 1971. *Analiza i prognoza obciążeń elektroenergetycznych*. Wydawnictwa Naukowo - Techniczne. Warszawa. 1971.
356. Witkowska D. 2002. *Sztuczne sieci neuronowe i metody statystyczne*. Wybrane zagadnienia finansowe. C.H. Beck. Warszawa.
357. Witkowska D. 2005. *Podstawy ekonometrii i teorii prognozowania*. Podręcznik z przykładami i zadaniami, Oficyna Ekonomiczna, Kraków.
358. Woźniak R. 2015. Rozprawa doktorska. *Ekonometryczne modelowanie popytu na energię elektryczną za pomocą danych wysokiej częstotliwości*. Uniwersytet Warszawski, Wydział Nauk Ekonomicznych, Warszawa, czerwiec. 2015.
359. Wu P., Tan J. 2018. *The Design of Distributed Power Big Data Analysis Framework and its Application in Residential Electricity Analysis*. 2018 Sixth International Conference on Advanced Cloud and Big Data. Wydawnictwo IEEE. 2015.
360. Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu. 2011. *Prakseologiczne aspekty prognozowania*. Prace Naukowe UE we Wrocławiu nr 185. Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu. Wrocław 2011, Str. 59 - 67.
361. Wyzumski T. 2005. *Prognozowanie neuronowe w energetyce*. Konferencja Naukowa Rynek Energii Elektrycznej - Materiały Konferencyjne, 25 - 27 kwietnia 2005, Kazimierz Dolny.
362. Xu Z., Dong Z. Y., Liu W.Q. 2005. *Neural Network Models For Electricity Market Forecasting*. w: Wang D., Lee N. K. (red.). 2005. *Neural Networks Applications in Information Technology and Web Engineering*. Borneo Publishing Co. Sarawak. Malaysia.
363. Yang J. 2006. *Power System Short-term Load Forecasting*. TU Darmstadt. Doktor-Ingenieurin (Dr. - Ing.) vorgelegte Dissertation. D17 Darmstädter Dissertation. Tag der mündlichen Prüfung: 17 - 02.
364. Yindong Y., Zhongqin B. 2014. *Advances and Future Challenges in Electric Power Big Data*. Wydawnictwo IEEE. 2014.
365. Yu X., Ji H. 2015. *A PSO - SVM - based 24 Hours Power Load Forecasting Model*. MATEC Web of Conferences 25, 01008 (2015). EDP Sciences, 2015. Article available at <http://www.matec-conferences.org>.
366. Yuan Q., Zhou K., Lu W., Yao J. 2018. *Big Data Driven Optimal Sizing of Stand-alone Photovoltaic Energy Systems*. Wydawnictwo IEEE. 2018.
367. Yule G. U. 1927. *On a Method of Investigating Periodicities in Disturbed Series, with Special Reference to Wolfer's Sunspot Numbers*. Philosophical Transactions of the Royal Society of London. Ser. A, Vol. 226, pp. 267 - 298.
368. Zalewski W. 2011. *Wpływ czynników atmosferycznych na zmienność zużycia energii elektrycznej*. Economy and Management - 4/2011. Politechnika Białostocka, Wydział Zarządzania, Katedra Informatyki Gospodarczej i Logistyki.

369. Zeliaś A. 1997. Teoria prognozy (PWE, Warszawa 1997). Str. 25.
370. Zeliaś A., Pawełek B., Wanat S. 2002. *Metody statystyczne - Zadania i sprawdziany*. Polskie Wydawnictwo Ekonomiczne. Warszawa.
371. Zeliaś A., Pawełek B., Wanat S. 2003. *Prognozowanie ekonomiczne. Teoria, przykłady, zadania*. Wydawnictwo Naukowe PWN, Warszawa 2003, s. 10, 16 - 18, 23 - 24, 141, 241, 247, 249 - 251, 270 - 309.
372. Zellner A. 1970. *Estimation of Regression Relationships Containing Unobservable Independent Variables*. "International Economic Review". October. Pp. 441 - 454, w: Maddala G.S. 2008. *Ekonometria*. Wydawnictwo Naukowe PWN.
373. Zhan J., Huang J., Niu L., Peng X., Deng D., Cheng S. 2014. *Study of the Key Technologies of Electric Power Big Data and its Application Prospects in Smart Grid*. Wydawnictwo IEEE.
374. Zieliński J.S. 1998. *Artificial Intelligence Contemporary Applications in Power Systems*. IV Sympozjum Metody Matematyczne w Elektroenergetyce, Zakopane 22 - 24 października 1998 r., Sekcja II: Optymalizacja w elektroenergetyce (Ref. 15).
375. Żołneczko M., Wilk A. 2018. *Data Mining - Metody bez nauczyciela*. Materiały kursowe StatSoft Polska. Wydawnictwo StatSoft Polska Sp. z o.o. Kraków. Kraków. 29 - 30 października.
376. Witryna internetowa: <https://www.entsoe.eu/>.
377. Witryna internetowa: <https://www.rte-france.com/>.
378. Witryna internetowa: <https://www.svk.se/>.

Spis rysunków

Rys. 1.1.1. Elementy ekonometrii wykorzystane w rozprawie.....	29
Rys. 1.2.1. Elementy statystyki wykorzystane w rozprawie.....	30
Rys. 1.3.2.1. Zmienność średniego obciążenia dobowego KSE w latach 2009 – 2018 na tle średnich wartości wybranych parametrów meteorologicznych monitorowanych przez IMGW na terenie Polski.....	33
Rys. 1.3.2.2. Zmienność średniego obciążenia dobowego KSE na przykładzie 2015 roku na tle średnich wartości wybranych parametrów meteorologicznych monitorowanych przez IMGW na terenie Polski.....	34
Rys. 1.3.2.3. Zmienność średniego obciążenia dobowego KSE w latach 2009 – 2018.....	35
Rys. 1.3.2.4. Zmienność średniego obciążenia dobowego KSE w poszczególnych miesiącach roku kalendarzowego w latach 2009 – 2018.....	36
Rys. 1.3.2.5. Zmienność średniego obciążenia dobowego KSE w miesiącach dla poniedziałków w latach 2009 – 2018.....	37
Rys. 1.3.2.6. Maksymalne zapotrzebowanie na moc elektryczną w KSE w latach i kwartałach lat 2009 – 2018.....	38
Rys. 1.3.2.7. Maksymalne zapotrzebowanie na moc elektryczną w KSE w miesiącach lat 2009 – 2018.....	38
Rys. 1.3.2.8. Maksymalne zapotrzebowanie na moc elektryczną w KSE w dniach tygodnia lat 2009 – 2018.....	39
Rys. 1.3.2.9. Minimalne zapotrzebowanie na moc elektryczną w KSE w latach i kwartałach lat 2009 – 2018.....	40
Rys. 1.3.2.10. Minimalne zapotrzebowanie na moc elektryczną w KSE w miesiącach lat 2009 – 2018.....	40
Rys. 1.3.2.11. Minimalne zapotrzebowanie na moc elektryczną w KSE w dniach tygodnia lat 2009 – 2018.....	41
Rys. 1.3.2.12. Obciążenie KSE w godzinach doby w latach 2009 – 2018.....	42
Rys. 1.3.2.13. Obciążenie KSE w godzinach doby w 2018 roku.....	43
Rys. 1.3.2.14. Obciążenie KSE w godzinach doby w poszczególnych latach 2009 – 2018 w tak zwaną środę pomiarową.....	43
Rys. 1.3.2.15. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w styczniu w latach 2009 i 2018.....	44
Rys. 1.3.2.16. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w lipcu w latach 2009 i 2018.....	44
Rys. 1.3.2.17. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w styczniu (17 dni) w latach 2009 i 2018.....	45
Rys. 1.3.2.18. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w lipcu (23 dni) w latach 2009 i 2018.....	46
Rys. 1.3.2.19. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w pierwszym pełnym tygodniu lipca w latach 2009 i 2018.....	46
Rys. 1.3.2.20. Przebiegi krzywej zapotrzebowania na moc elektryczną w KSE w pierwszym pełnym tygodniu lipca w latach 2009 i 2018.....	47
Rys. 2.1. Skuteczność prognozowania modeli prognostycznych w zbiorze Top 10 z grupy 264 modeli.....	65
Rys. 3.1.1. Przykład korelogramu funkcji autokorelacji ACF i PACF zapotrzebowania na moc elektryczną w KSE w 2018 roku dla opóźnienia 48 dób.....	79
Rys. 3.1.2. Przykłady korelogramów funkcji autokorelacji ACF i PACF zapotrzebowania na moc elektryczną w KSE: a) i b) w okresie 2009 – 2018 dla wszystkich godzin 02:00, c) i d) w okresie 365 dni dla wszystkich godzin 02:00, e) i f) w okresie 344 dni dla wszystkich godzin 02:00.....	80

Spis tabel

Tab. 2.1. Stan badań.....	66
Tab. 3.7.1. Skuteczność roczna prognoz osiąganych przy pomocy metody ważonych współczynników funkcji autokorelacji cząstkowej a skuteczność prognoz w ramach BPKD (podejście klasyczne a podejście krokowe) wyrażona wartościami błędu MAPE, [%].....	93
Tab. 4.1.1.1. Kryteria dopuszczalności prognoz w literaturze przedmiotu i zastosowane w rozprawie.	94
Tab. 4.1.3.1. Dopuszczalność prognoz w podziale lata oraz na typy dni i godziny doby dla metody ważonych współczynników funkcji autokorelacji cząstkowej.....	95
Tab. 4.1.3.2. Dopuszczalność prognoz w poszczególnych latach 2009 – 2018 w godzinach 00:00 – 05:00 dla metody ważonych współczynników funkcji autokorelacji cząstkowej.	96
Tab. 4.1.3.3. Dopuszczalność prognoz w poszczególnych latach 2009 – 2018 w godzinach 06:00 – 23:00 dla metody ważonych współczynników funkcji autokorelacji cząstkowej.	96
Tab. 4.1.4.1. Dopuszczalność prognoz w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, w podziale na typy dni.....	97
Tab. 4.1.4.2. Dopuszczalność prognoz w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, w podziale na typy dni.....	97
Tab. 4.1.5.1. Dopuszczalność prognoz w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S01 do S16.....	98
Tab. 4.1.5.2. Dopuszczalność prognoz w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S01 do S16.....	99
Tab. 4.1.5.3. Dopuszczalność prognoz w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S01 do S16.....	99
Tab. 4.1.5.4. Dopuszczalność prognoz w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S01 do S16.....	100
Tab. 4.2.1.1. Skuteczność roczna prognoz oraz w podziale na typy dni i godziny doby w ramach planów BPKD wyrażona wartościami błędu MAPE, [%].	101
Tab. 4.2.1.2. Skuteczność prognoz w poszczególnych latach 2009 – 2018 w godzinach 00:00 – 05:00 doby w ramach planów BPKD wyrażona wartościami błędu MAPE, [%].	101
Tab. 4.2.1.3. Skuteczność prognoz w poszczególnych latach 2009 – 2018 w godzinach 06:00 – 23:00 doby w ramach planów BPKD wyrażona wartościami błędu MAPE, [%].	102
Tab. 4.2.1.4. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ w ramach planów BPKD w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].	102
Tab. 4.2.1.5. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ w ramach planów BPKD w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].	103
Tab. 4.2.1.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ w ramach planów BPKD w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].	103
Tab. 4.2.1.7. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ w ramach planów BPKD w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].	104
Tab. 4.2.1.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ w ramach planów BPKD w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].	104

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

<i>Tab. 4.2.1.9. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ w ramach planów BPKD w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>	<i>105</i>
<i>Tab. 4.2.2.1. Skuteczność roczna prognoz oraz w podziale na typy dni i godziny doby dla metody ważonych współczynników funkcji autokorelacji cząstkowej, wyrażona wartościami błędu MAPE, [%].</i>	<i>106</i>
<i>Tab. 4.2.2.2. Skuteczność prognoz w poszczególnych latach 2009 – 2018 dla godzin 00:00 – 05:00 dla metody ważonych współczynników funkcji autokorelacji cząstkowej, wyrażona wartościami błędu MAPE, [%].</i>	<i>106</i>
<i>Tab. 4.2.2.3. Skuteczność prognoz w poszczególnych latach 2009 – 2018 dla godzin 06:00 – 23:00 dla metody ważonych współczynników funkcji autokorelacji cząstkowej, wyrażona wartościami błędu MAPE, [%].</i>	<i>107</i>
<i>Tab. 4.2.2.4. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla modelu ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].</i>	<i>107</i>
<i>Tab. 4.2.2.5. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla modelu ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].</i>	<i>108</i>
<i>Tab. 4.2.2.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla modelu ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].</i>	<i>109</i>
<i>Tab. 4.2.2.7. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla modelu ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>	<i>109</i>
<i>Tab. 4.2.2.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].</i>	<i>110</i>
<i>Tab. 4.2.2.9. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>	<i>110</i>
<i>Tab. 4.2.3.1. Skuteczność roczna prognoz oraz w podziale na typy dni i godziny doby dla metody ważonych współczynników funkcji autokorelacji cząstkowej w porównaniu do prognozowania dla KSE, wyrażona wartościami błędu MAPE, [%].</i>	<i>112</i>
<i>Tab. 4.2.3.2. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>	<i>112</i>
<i>Tab. 4.2.3.3. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w poszczególnych latach 2009 - 2018, wyrażona wartościami błędu MAPE, [%].</i>	<i>113</i>
<i>Tab. 4.2.3.4. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].</i>	<i>113</i>
<i>Tab. 4.2.3.5. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie $n+1$ dla metody ważonych współczynników funkcji autokorelacji cząstkowej</i>	

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

<i>w odniesieniu do planów BPKD w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].</i>	114
<i>Tab. 4.2.3.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].</i>	115
<i>Tab. 4.2.3.7. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>	115
<i>Tab. 4.2.3.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].</i>	115
<i>Tab. 4.2.3.9. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>	116
<i>Tab. 4.2.3.10. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>	116
<i>Tab. 4.2.3.11. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do planów BPKD w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>	117
<i>Tab. 4.2.4.1. Skuteczność roczna prognoz oraz w podziale na typy dni i godziny doby dla hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej, wyrażona wartościami błędu MAPE, [%].</i>	118
<i>Tab. 4.2.4.2. Liczba prognoz w poszczególnych latach 2009 – 2018 oraz w podziale na typy dni i godziny doby w godzinach 00:00 – 05:00 doby, w których metoda ważonych współczynników funkcji autokorelacji cząstkowej cechuje się skutecznością większą niż osiąganą przez PSE S.A. wyrażona wartościami procentowymi, [%].</i>	119
<i>Tab. 4.2.4.3. Liczba prognoz w poszczególnych latach 2009 – 2018 oraz w podziale na typy dni i godziny doby w godzinach 06:00 – 23:00 doby, w których metoda ważonych współczynników funkcji autokorelacji cząstkowej cechuje się skutecznością większą niż osiąganą przez PSE S.A. wyrażona wartościami procentowymi, [%].</i>	119
<i>Tab. 4.2.4.4. Skuteczność prognoz w poszczególnych latach 2009 – 2018 w godzinach 00:00 – 05:00 doby dla hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej wyrażona wartościami błędu MAPE, [%].</i>	120
<i>Tab. 4.2.4.5. Skuteczność prognoz w poszczególnych latach 2009 – 2018 w godzinach 06:00 – 23:00 doby dla hybrydowej integracji wyników PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej wyrażona wartościami błędu MAPE, [%].</i>	120
<i>Tab. 4.3.1. Systemy elektroenergetyczne krajów wyznaczone do walidacji.</i>	121
<i>Tab. 4.3.2. Wykaz dni świątecznych wolnych od pracy na tle dni świątecznych i niestandardowych w Polsce wytypowanych do analiz walidacyjnych.</i>	121
<i>Tab. 4.3.1.1. Skuteczność prognozowania w latach kalendarzowych w horyzoncie n+1 dla zagranicznych SEE latach 2013 – 2018, wyrażona minimalnymi wartościami błędu MAPE, [%].</i>	122
<i>Tab. 4.3.1.2. Skuteczność prognozowania w latach kalendarzowych w horyzoncie n+1 dla zagranicznych SEE w okresie 2013 – 2018, wyrażona wartościami błędu MAPE, [%].</i>	122

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

<i>Tab. 4.3.1.3. Skuteczność prognozowania w latach kalendarzowych w horyzoncie n+1 dla zagranicznych SEE latach 2013 – 2018 wyrażona maksymalnymi wartościami błędu MAPE, [%].....</i>	<i>122</i>
<i>Tab. 4.3.2.1. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>	<i>123</i>
<i>Tab. 4.3.2.2. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>	<i>123</i>
<i>Tab. 4.3.2.3. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].....</i>	<i>124</i>
<i>Tab. 4.3.2.4. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].....</i>	<i>124</i>
<i>Tab. 4.3.2.5. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>	<i>125</i>
<i>Tab. 4.3.2.6. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu szwedzkiego SEE w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>	<i>125</i>
<i>Tab. 4.3.3.1. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>	<i>126</i>
<i>Tab. 4.3.3.2. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>	<i>126</i>
<i>Tab. 4.3.3.3. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].....</i>	<i>127</i>
<i>Tab. 4.3.3.4. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].....</i>	<i>127</i>
<i>Tab. 4.3.3.5. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>	<i>128</i>
<i>Tab. 4.3.3.6. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu francuskiego SEE w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>	<i>128</i>

<i>Tab. 4.4.1.1. Wybrane metody i modele prognostyczne wobec metody ważonych współczynników funkcji autokorelacji cząstkowej w horyzoncie n+1 w podziale na grupy modeli i metod w okresie analizy 2009 – 2018.....</i>	<i>129</i>
<i>Tab. 4.4.2.1. Skuteczność prognozowania dla wybranych metod prognostycznych wraz z czasochłonnością ich opracowania wobec skuteczności PSE S.A. i metody ważonych współczynników funkcji autokorelacji cząstkowej w horyzoncie n+1 w okresie analizy 2009 – 2018 wyrażona wartościami błędu MAPE, [%].....</i>	<i>132</i>
<i>Tab. 4.4.3.1. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>	<i>133</i>
<i>Tab. 4.4.3.2. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>	<i>134</i>
<i>Tab. 4.4.3.3. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].....</i>	<i>134</i>
<i>Tab. 4.4.3.4. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].....</i>	<i>135</i>
<i>Tab. 4.4.3.5. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].</i>	<i>135</i>
<i>Tab. 4.4.3.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>	<i>136</i>
<i>Tab. 4.4.3.7. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].</i>	<i>136</i>
<i>Tab. 4.4.3.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>	<i>137</i>
<i>Tab. 4.4.3.9. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>	<i>138</i>
<i>Tab. 4.4.3.10. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu ARIMA w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>	<i>138</i>
<i>Tab. 4.4.4.1. Skuteczność prognozowania w latach kalendarzowych w horyzoncie n+1 dla modeli naiwnych w latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%]....</i>	<i>139</i>
<i>Tab. 4.4.5.1. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej</i>	

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

	<i>w odniesieniu do modelu 7 dób metody naiwnej w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>	140
<i>Tab. 4.4.5.2. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>		140
<i>Tab. 4.4.5.3. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].</i>		141
<i>Tab. 4.4.5.4. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].</i>		141
<i>Tab. 4.4.5.5. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].</i>		142
<i>Tab. 4.4.5.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>		142
<i>Tab. 4.4.5.7. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].</i>		143
<i>Tab. 4.4.5.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>		144
<i>Tab. 4.4.5.9. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>		144
<i>Tab. 4.4.5.10. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 7 dób metody naiwnej w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>		145
<i>Tab. 4.4.6.1. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>		145
<i>Tab. 4.4.6.2. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w poszczególnych latach 2009 – 2018, wyrażona wartościami błędu MAPE, [%].</i>		146
<i>Tab. 4.4.6.3. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].</i>		146
<i>Tab. 4.4.6.4. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej</i>		

*Prognozowanie krótkoterminowego zapotrzebowania na moc elektryczną
metodą ważonych współczynników funkcji autokorelacji cząstkowej*

	<i>w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].....</i>	<i>147</i>
<i>Tab. 4.4.6.5. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].</i>	<i>.....</i>	<i>148</i>
<i>Tab. 4.4.6.6. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>	<i>.....</i>	<i>148</i>
<i>Tab. 4.4.6.7. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S01 do S08, wyrażona wartościami błędu MAPE, [%].</i>	<i>.....</i>	<i>149</i>
<i>Tab. 4.4.6.8. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w latach 2009 – 2018, dla dni świątecznych od S09 do S16, wyrażona wartościami błędu MAPE, [%].</i>	<i>.....</i>	<i>149</i>
<i>Tab. 4.4.6.9. Skuteczność prognozowania w godzinach 00:00 – 05:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>	<i>.....</i>	<i>150</i>
<i>Tab. 4.4.6.10. Skuteczność prognozowania w godzinach 06:00 – 23:00 w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do modelu 1 doby metody naiwnej w poszczególnych latach 2009 – 2018, dla dni świątecznych, wyrażona wartościami błędu MAPE, [%].</i>	<i>.....</i>	<i>150</i>
<i>Tab. 4.5.1. Skuteczność prognozowania dla wszystkich godzin doby w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do analizowanych metod i modeli prognostycznych w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].</i>	<i>.....</i>	<i>152</i>
<i>Tab. 4.5.2. Skuteczność prognozowania dla wszystkich godzin doby w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do analizowanych metod i modeli prognostycznych w latach 2009 – 2018, w podziale na typy dni, wyrażona wartościami błędu MAPE, [%].</i>	<i>.....</i>	<i>153</i>
<i>Tab. 4.5.3. Skuteczność prognozowania dla wszystkich godzin doby w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do analizowanych metod i modeli prognostycznych w latach 2009 – 2018, dla dni świątecznych i niestandardowych, wyrażona wartościami błędu MAPE, [%].</i>	<i>.....</i>	<i>154</i>
<i>Tab. 4.5.4. Skuteczność prognozowania dla wszystkich godzin doby w horyzoncie n+1 dla metody ważonych współczynników funkcji autokorelacji cząstkowej w odniesieniu do analizowanych metod i modeli prognostycznych w latach 2009 – 2018, dla dni świątecznych i niestandardowych, wyrażona wartościami błędu MAPE, [%].</i>	<i>.....</i>	<i>155</i>