

## DOKŁADNOŚĆ PROGNOZOWANIA ZAPOTRZEBOWANIA NA CIEPŁO W SZKLARNI

Sławomir GRABARCZYK

*Politechnika Warszawska, Filia w Płocku  
Instytut Budownictwa, Zespół Instalacji Budowlanych i Fizyki Budowli  
ul. Łukasiewicza 17, 09-400 Płock, e-mail: slawekg@pw.plock.pl*

**Streszczenie:** Krótkoterminowe prognozy zapotrzebowania na ciepło dają możliwość zwiększenia wydajności produkcji ciepła, zmniejszenia zużycia paliwa i emisji produktów spalania do atmosfery. W artykule przedstawiono problem dokładności prognozowania zapotrzebowania na ciepło w szklarni z wykorzystaniem metod SARIMA. Źródłem informacji do analizy szeregów czasowych były dane eksploatacyjne zużycia ciepła.

**Słowa kluczowe:** szklarnia, prognozowanie, szereg czasowy, zapotrzebowanie na ciepło, błąd prognozy

### 1. WPROWADZENIE

W artykule przedstawiono zagadnienie dotyczące dokładności prognozowania zapotrzebowania na ciepło w szklarni, budynku o istotnym wpływie zewnętrznych czynników klimatycznych.

Prognozowanie zapotrzebowania na ciepło można zrealizować korzystając z lokalnych prognoz meteorologicznych [3], wprowadzając informacje o parametrach powietrza zewnętrznego do modelu budynku, który jest sprzęgnięty z systemem sterowania i pozwala na bieżąco określić potrzeby ciepłne obiektu.

Stosowanie innych narzędzi prognostycznych w analizie zapotrzebowania na ciepło było przedmiotem szeregu publikacji, min. dotyczących systemów ciepłowniczych [12] czy obiektów szklarniowych [5][6]. Metodami, które pozwalają na identyfikację natury zjawiska są szeregi czasowe, dające możliwość zastosowania ich do innych danych. Służą one do prognozowania przyszłych wartości szeregu czasowego, bazując tylko i wyłącznie na obserwacjach poprzedzających zmiennej prognozowanej. Zaletą takiej prognozy jest oczywiście niezależ-

nienie się od szeregu zmiennych, które mają wpływ na wielkość zużycia ciepła.

Modele szeregów czasowych ARIMA zdobyły popularność w wielu dziedzinach, głównie w wyniku pracy opublikowanej przez Boxa i Jenkinsa [2]. Przykładem może tu być zastosowanie szeregów czasowych SARIMA do prognozowania popytu na energię pierwotną w skali całego państwa na przykładzie Turcji [4], czy też przedmiotem analiz w przewidywaniu zapotrzebowania na energię elektryczną [10][13].

Zastosowanie szeregów czasowych ARMA zostało wysoko ocenione, jako jedna z metod o wysokiej dokładności w szacowaniu potrzeb ciepłnych budynków, mimo że są to metody o umiarkowanym stopniu trudności [1]. Modele szeregów czasowych ARIMA i SARIMA, z racji na większą liczbę parametrów, są modelami o większym stopniu trudności, to jednak zalety tych metod i możliwa do osiągnięcia duża dokładność spowodowały o zastosowaniu ich w prognozowaniu zapotrzebowania na ciepło dla szklarni.

Prognozowanie zapotrzebowania na ciepło w obiektach szklarniowych wynika z konieczności zapewnienia odpowiedniej temperatury wewnętrznej. Lekka konstrukcja szklarni i znaczny wpływ zmiennych warunków zewnętrznych na mikroklimat powoduje, że utrzymanie zadanej temperatury w pewnych okresach w szklarni może sprawiać problem. Ponadto, argumentem przemawiającym za stosowaniem prognoz zapotrzebowania na ciepło w szklarni jest brak akumulacji ciepła w obiekcie tego typu oraz znaczna bezwładność źródła ciepła i systemu jego dystrybucji, zwłaszcza w dużych kompleksach szklarniowych.

W szeregach ARIMA można zaobserwować dwa typowe procesy. Pierwszy z nich to proces autoregresyjny, który

określa że wartość szeregu jest sumą składnika losowego oraz kombinacji poprzednich obserwacji. Drugi to proces średniej ruchomej, w którym każdy element szeregu może pozostawać pod wpływem realizacji składnika losowego w okresach przeszłych, który to wpływ nie może być wyjaśniony przez składnik autoregresyjny. Oprócz typowych procesów, z uwagi na konieczność doprowadzenia szeregu do stacjonarności, wprowadza się tzw. integrację w/w procesów, realizowaną przez różnicowanie wartości szeregu.

Podstawowymi wymogami zastosowania szeregów ARIMA w prognozowaniu konkretnych danych jest to aby średnia procesu w każdej chwili była taka sama, wariancja procesu również, funkcje autokorelacji zależały od opóźnienia a nie zależały od czasu. Modele ARIMA nie nadają się najlepiej do prognozowania szeregów z sezonowością, dlatego też wprowadza się jeszcze do modelu różnicowanie sezonowe (model SARIMA).

Ocenę dokładności prognozowania i trafności prognoz możemy dokonać stosując mierniki dokładności *ex ante* i *ex post*. Błędy *ex ante* to oczekiwana różnica pomiędzy wartością prognozy oraz nieznaną, w chwili stawiania prognozy, wartością rzeczywistą. Wartość tego błędu jest związana z okresem, na który stawia się prognozę a także dobrocią dopasowania modelu do danych. Im dalej w przyszłość stawiane są prognozy tym większą niepewnością są obciążone. Właściwszą oceną trafności wyznaczonych prognoz jest ustalenie błędów *ex post*, gdy zaistnieje ku temu okazja. Błąd *ex post*, ustalany po zaistnieniu obserwacji zmiennej prognozowanej w czasie i sprawdzeniu wartości prognoz z rzeczywistymi wynikami. Takie prognozy, wyznaczane sekwencyjnie, umożliwiają zdiagnozowanie ich słabej jakości, pozwalają na weryfikację modelu i wprowadzenie do niego poprawek. Korzyścią jest również to, że niska trafność prognoz jest zwykle wynikiem nieuwzględnienia w modelu prognostycznym pojawiającej się nowej informacji. Trafność prognoz ilościowych w typowym szeregu czasowym można określić na kilka sposobów. Stosuje się w tym celu mierniki bezwzględne – zachowujące jednostkę pomiaru zmiennej prognozowanej oraz mierniki względne – umożliwiające porównanie prognoz uzyskanych różnymi metodami prognostycznymi.

Celem przedstawionych w pracy analiz było zwrócenie uwagi na zagadnienie dokładności prognoz zapotrzebowania na ciepło dla budynku szklarni.

## 2. ZAŁOŻENIA DO BADAŃ I ANALIZ

Obiektem badań jest budynek szklarni z ekranem termizolacyjnym, którego zadaniem jest dopasowanie właściwości przegrody zewnętrznej do zmiennych warunków otoczenia. W analizach wykorzystano zbiór danych

z godzinowym interwałem między kolejnymi pomiarami zużycia energii. Taki odstęp między kolejnymi pomiarami, pozwala na odzwierciedlenie funkcjonowania wyposażenia technicznego szklarni, obiektu o istotnym wpływie zewnętrznych warunków klimatycznych na temperaturę wewnętrzną a tym samym na zużycie ciepła.

Badania przeprowadzono na przełomie 2007 i 2008 roku. Zgromadzony materiał badawczy obejmuje wyniki pomiarów z miesiący okresu zimowego. Łączna ilość danych wykorzystanych w analizie to 4344 rekordy.

Źródłem danych o wielkości zużycia ciepła jest ciepłomierz zainstalowany na przewodzie powrotnym systemu grzewczego. Przyrząd ten mierzy wartości zużycia ciepła, a zatem zarejestrowany szereg danych to tzw. szereg nieujemny.

Szereg danych pomiarowych zużycia ciepła nie jest typowym szeregiem dla którego można było użyć wskaźników [9][11] związanych z identyfikacją liczby parametrów modelu. Wstępne obserwacje i charakter gromadzonych danych wskazywały, że są one obciążone sezonowością, a zatem spodziewano się, że docelowo będzie to model SARIMA.

Estymację parametrów szeregu oraz obliczenia sumy kwadratów reszt, przy zadanych parametrach, wykonano metodą dokładną największej wiarygodności według Melarda, bez uwzględniania stałej.

W celu przeprowadzenia analiz prognozowania zapotrzebowania na ciepło, szereg danych został doprowadzony do stacjonarności. Dodatkowo szereg danych został zlogarytmowany w celu stabilizacji wariancji. Po wstępnych analizach przyjęto, że opóźnienie sezonowe (okres) stosowane dla sezonowych parametrów autoregresyjnych i średniej ruchomej jest równe 12.

W wyniku analiz stwierdzono, że najodpowiedniejszy w prognozowaniu zapotrzebowania na ciepło będzie model SARIMA (2,1,2)(2,0,1)<sup>12</sup> czyli model autoregresyjny drugiego rzędu, z dwoma niesezonowymi parametrami średniej ruchomej, w którym są dwa sezonowe parametry autoregresyjne oraz jeden sezonowy parametr średniej ruchomej. Parametry te zostały oszacowane dla szeregu po jednokrotnym różnicowaniu, przy opóźnieniu równym jeden. Wyniki estymacji parametrów modelu SARIMA przedstawiono w Tab. 1.

Ocenę parametrów w module szeregów czasowych obliczono wyznaczając tak zwane asymptotyczne błędy standardowe. Są one obliczane z macierzy pochodnych cząstkowych drugiego rzędu, która jest aproksymowana przy pomocy różnicowania skończonego. Zminimalizowana suma kwadratów reszt (warunkowa), dla określonych w analizach parametrów modelu SARIMA, wynosi 34,5% wartości początkowej sumy kwadratów.

Tabela 1. Wyniki estymacji modelu SARIMA.  
Table 1. SARIMA model estimation results.

parametr	Asympt. błąd std.	Asympt. t	p	Dolna gr 95% p. ufn.	Górna gr 95% p. ufn.	
p(1)	0,598	0,0428	13,97	0,00	0,514	0,682
p(2)	0,225	0,0426	5,28	0,00	0,142	0,309
q(1)	0,723	0,0435	16,64	0,00	0,638	0,808
q(2)	-0,213	0,0400	-5,32	0,00	-0,291	-0,134
Ps(1)	0,846	0,0161	52,56	0,00	0,815	0,878
Ps(2)	0,149	0,0159	9,35	0,00	0,118	0,180
Qs(1)	0,935	0,0072	129,78	0,00	0,921	0,949

Wykonane testy i analizy pozwoliły na określenie modelu szeregu czasowego SARIMA, uwzględniającego zarówno opóźnienia autoregresyjne oraz elementy średniej ruchomej przy jednokrotnym zróżnicowaniu szeregu. Model SARIMA przyjęto na podstawie analizy wyników dopasowania modelu, w których parametry przy opóźnieniach autoregresyjnych oraz dla średniej ruchomej są statystycznie istotne  $p < 0.05$ . Analiza reszt modelu wykazała, że mają one w przybliżeniu rozkład normalny.

Analiza autokorelacji cząstkowej reszt modelu dla kolejnych opóźnień autoregresyjnych wykazała, że nie istnieją korelacje dla 12 kolejno następujących po sobie obserwacji, a zatem szereg jest poprawnie zbudowany, przy czym istotne jest to, że siła korelacji w tej analizie jest ważniejsza niż efektywność estymacji [8].

Tak zbudowany model prognostyczny można poddać ocenie dokładności prognoz, których najprostszymi miernikami są błędy bezwzględne:

- bezwzględny błąd prognozy ex post, obliczany, jako różnica zmiennej obserwowanej  $y_t$  i zmiennej prognozowanej  $y_t^p$ :

$$E_t = y_t - y_t^p \quad (1)$$

- średni błąd  $ME$ , określany w danym momencie lub okresie:

$$ME = \frac{1}{m} \sum_{t=1}^m (y_t - y_t^p) \quad (2)$$

gdzie,  $m$  oznacza moment lub okres analizowanego przedziału czasu;

- średni błąd bezwzględny  $MAE$ , określany zależnością:

$$MAE = \frac{1}{m} \sum_{t=1}^m |y_t - y_t^p| \quad (3)$$

- pierwiastek błędu średniokwadratowego  $RMSE$ , określany ze wzoru:

$$RMSE = \sqrt{\frac{1}{m} \sum_{t=1}^m (y_t - y_t^p)^2} \quad (4)$$

- średni bezwzględny skalowany błąd  $MASE$ , określony równaniem:

$$MASE = \frac{E_t}{\frac{1}{m-1} \sum_{t=1}^m |y_t - y_{t-1}|} \quad (5)$$

który to miernik stanowi porównywanie otrzymanego błędu z błędem, który popełnilibyśmy konstruując prognozy za pomocą metody naiwnej – w tym przypadku, jako prognozę dla kolejnych okresów przyjmujemy ostatnią z zaobserwowanych wartości.

Z mierników względnych wyróżnić trzeba:

- średni bezwzględny błąd procentowy  $MAPE$ , określany zależnością:

$$MAPE = \frac{1}{m} \sum_{t=1}^m \left| \frac{y_t - y_t^p}{y_t} \right| \cdot 100 \quad (6)$$

- względny błąd predykcji ex post, obliczany, jako:

$$V_{RMSE} = \frac{RMSE}{|\bar{y}_t|} \cdot 100 \quad (7)$$


### 3. WYNIKI BADAŃ

Pełny opis analiz przedmiotowego modelu SARIMA przedstawiono we wcześniejszej publikacji [7]. Analiza wyników prognoz zapotrzebowania na ciepło dla szklarni w okresie od listopada do kwietnia pozwala stwierdzić, że jeden miesięczny okres danych pozwala na budowę modelu SARIMA o opisanych wcześniej parametrach, ale jeden z nich jest nieistotny statystycznie. Dwumiesięczny okres, będący podstawą do budowy modelu prognostycznego, pozwala na uzyskanie stabilnego szeregu czasowego o istotnych statystycznie parametrach.

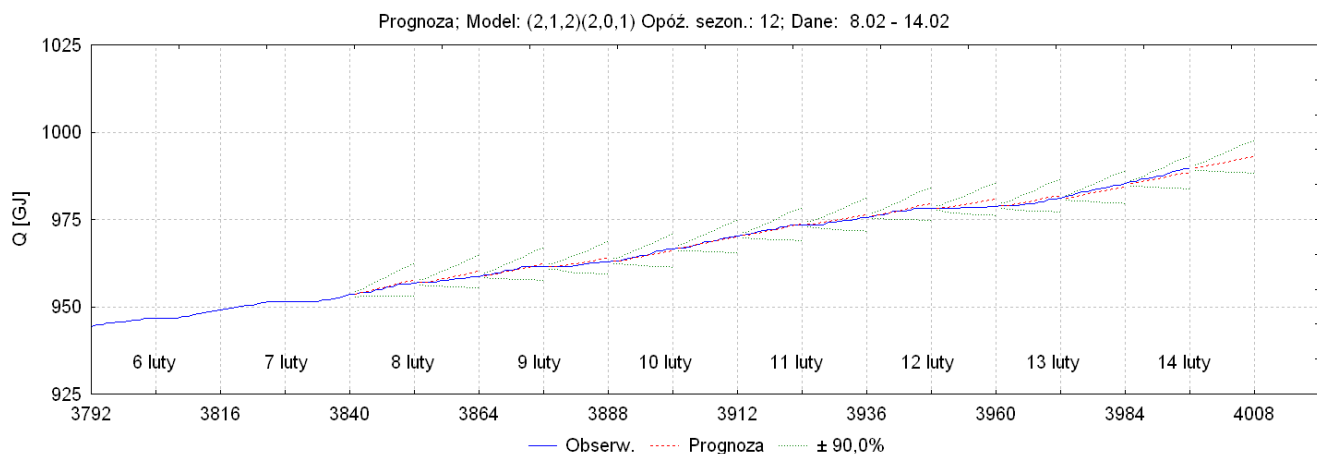
W artykule zaprezentowano przedziałowe wyniki prognozy dla 12 godzinnych okresów (po dwie prognozy dla każdej doby) przy założeniu, że prognozę zapotrzebowania na ciepło wyznacza się od godz. 0:00 do godz. 11:00 oraz od godz. 12:00 do godz. 23:00.

Prognozy zapotrzebowania na ciepło dla szklarni wykonano dla dwóch przykładowych miesięcy: lutego - miesiąca okresu zimowego, i dla kwietnia - miesiąca okresu przejściowego. Na rys. 1 - 4 przedstawiono wyniki takich prognoz zapotrzebowania na ciepło wraz z przedziałem ufności, nałożone na rzeczywisty przebieg zużycia ciepła w miesiącu lutym. Prognozy wykonywano sekwencyjnie, a każdy rysunek przedstawia wyniki dla tygodnia.


W każdym momencie prognozowania zapotrzebowania na ciepło, wykonywanym sekwencyjnie dla 12 kolejnych obserwacji, oceny parametrów modelu SARIMA, w miesiącu lutym dla 56 prognoz, a w miesiącu kwietniu dla 60 prognoz, wszystkie parametry okazały się istotne statystycznie, tzn. model w całym okresie prognozowania był pozytywnie weryfikowany.



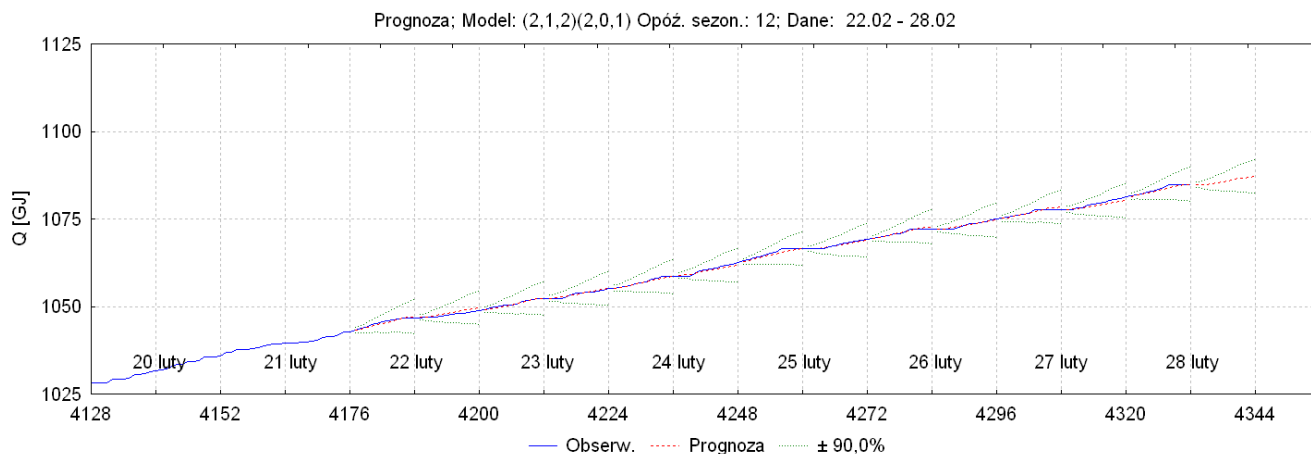
Rys. 1. Wykres zmiennej obserwowanej i prognozowanej z 90% przedziałem ufności: 1 – 7 luty.  
 Fig. 1. The graph of value of the observed and the forecasts with the 90% confidence limits: 1 – 7 February.



Rys. 2. Wykres zmiennej obserwowanej i prognozowanej z 90% przedziałem ufności: 8 – 14 luty.  
 Fig. 2. The graph of value of the observed and the forecasts with the 90% confidence limits: 8 – 14 February.



Rys. 3. Wykres zmiennej obserwowanej i prognozowanej z 90% przedziałem ufności: 15 – 21 luty.  
 Fig. 3. The graph of value of the observed and the forecasts with the 90% confidence limits: 15 – 21 February.



Rys. 4. Wykres zmiennej obserwowanej i prognozowanej z 90% przedziałem ufności: 22 – 28 luty.  
 Fig. 4. The graph of value of the observed and the forecasts with the 90% confidence limits: 22 – 28 February.


Wyniki takich prognoz sekwencyjnego zapotrzebowania na ciepło dla szklarni były podstawą obliczenia błędu prognozy ex post.

Z uwagi na charakter danych rzeczywistego zużycia energii zaproponowano wykorzystanie w ocenie jakości prognoz błędu bezwzględnego oraz pierwiastka błędu średniokwadratowego prognoz ex post. Przyczyną takiego założenia jest to, że:

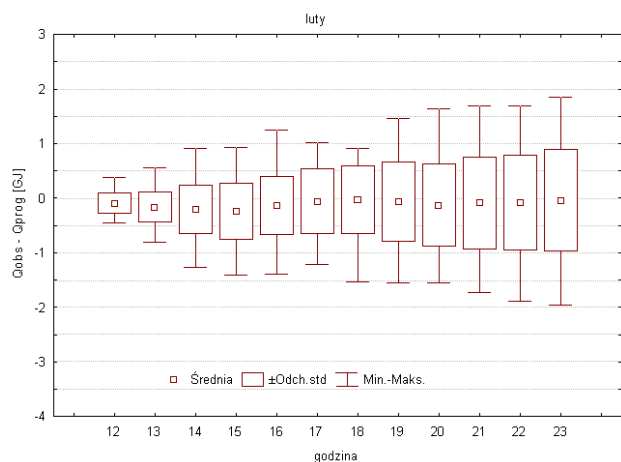
- obliczenie błędu względnego w odniesieniu do wartości pomiarowej, wskazanej przez przelicznik ciepłomierza oznacza, że błąd ten maleje wraz z czasem funkcjonowania systemu grzewczego – szereg danych pomiarowych niujemny; po za tym błąd prognozy do wartości szeregu niezróżnicowanego, to nadmiernie optymistyczny błąd względny, tu rzędu dziesiątych i setnych części procenta;
- obliczenie błędu prognozy do wartości szeregu zróżnicowanego – może powodować zawyżanie średniego błędu prognozy, który „stanowi” znaczącą część wartości prognozowanej;
- obserwacje zerowe rzeczywistego zużycia energii, będące podstawą prognoz, nie pozwalają na określenie właściwego błędu względnego, ponieważ rośnie on do nieskończoności. Wstępna ocena modelu SARIMA pod względem dokładności prognoz opiera się zatem na różnicy bezwzględnej wartości obserwowanej i prognozowanej, czyli bezwzględny błąd prognozy ex post.

Zwiększenie dokładności prognoz uzyskać przez skrócenie czasookresu między wyznaczaniem prognoz, ponieważ zaobserwowane różnice są najmniejsze dla pierwszych trzech obserwacji po wykonaniu prognozy - przykładowe wykresy wykonane dla lutego i kwietnia ilustrują to graficznie (rys. 5 - 8).

W miesiącu lutym obserwowano częste występowanie dostaw strumienia ciepła do systemu grzewczego szklarni w całym przekroju doby, a zatem wartości średniego bezwzględnego błędu prognozy ex post oscylują wokół zera, przy czym rozrzut ich występowania i odchylenie standardowe jest typowe dla takiego rodzaju danych w szeregu czasowym (Rys. 5 i 6).




Rys. 5. Bezwzględny błąd prognozy ex post – luty, godz.: 0:00 – 11:00.  
 Fig. 5. Absolute forecast error ex-post – February, hour: 0:00 – 11:00.



Rys. 6. Bezwzględny błąd prognozy ex post – luty, godz.: 12:00 – 23:00.


Fig. 6. Absolute forecast error ex-post – February, hour: 13:00 – 24:00.

Analiza bezwzględnego błędu prognozy ex post w przekroju dobowym dla danych z miesiąca kwietnia (Rys. 7 i 8) wykazuje, że wartości błędu na początku okresu prognozy są niewielkie, ale ich rozrzut występowania jak i odchylenie standardowe w miarę oddalania się od momentu wykonania prognozy znacząco większe, niż miało to miejsce dla danych z miesiąca lutego (Rys. 5 i 6). Powodem jest występowanie obserwacji zerowych zużycia ciepła, a w konsekwencji obserwowania rosnącej wartości błędu w późniejszych momentach horyzontu prognozy.



Rys. 7. Bezwzględny błąd prognozy ex post – kwiecień, godz.: 0:00 – 11:00.

Fig. 7. Absolute forecast error ex-post – April, hour: 0:00 – 11:00.




Rys. 8. Bezwzględny błąd prognozy ex post – kwiecień, godz.: 12:00 – 23:00.

Fig. 8. Absolute forecast error ex-post – April, hour: 12:00 – 23:00.

Wykresy na rys. 5 - 8 ilustrują występowanie najmniejszego błędu dla pierwszych trzech obserwacji prognozowanych. W związku z tym postanowiono zwrócić uwagę na trafność prognozy z punktu widzenia horyzontu, który tu przyjęto, jako równy 12 obserwacjom.


W celu określenia dokładności prognozy, a jednocześnie zminimalizowania błędu, postanowiono określić przedział czasu, dla którego prognoza jest dopuszczalna.

Wyznaczono w tym celu wartości pierwiastka błędu średniokwadratowego prognoz ex post w analizowanych zakresach godzinowych. Na rys. 9 i 10 przedstawiono wartości tego błędu obliczone dla całego horyzontu prognozy  $RSME_{12}$  oraz dla poszczególnych momentów horyzontu  $RSME_m$ .



Rys. 9. Pierwiastek błędu średniokwadratowego prognoz ex post – luty, godz.: 0:00 – 11:00.

Fig. 9. Root mean square error ex post forecasts – February, hour: 0:00 – 11:00.



Rys. 10. Pierwiastek błędu średniokwadratowego prognoz ex post – luty, godz.: 12:00 – 23:00.

Fig. 10. Root mean square error ex post forecasts – February, hour: 12:00 – 23:00.

Wartości błędu *RSME* również wskazują, że błąd prognozy zapotrzebowania na ciepło jest najmniejszy w 2 - 3 pierwszych obserwacjach.

W celu ustalenia okresu dopuszczalnej prognozy, postanowiono wykorzystać średni bezwzględny błąd procentowy *MAPE* oraz średni bezwzględny błąd skalowany *MASE*.

Wyniki obliczeń błędów prognozy zapotrzebowania na ciepło, dla pierwszych obserwacji od momentu prognozy, przedstawiono w Tab. 2.

Tabela 2. Średni bezwzględny błąd procentowy *MAPE* i średni bezwzględny błąd skalowany *MASE*.

Table 2. Mean absolute percentage error *MAPE* and mean absolute scaled error *MASE*.

luty						
godz.	0	1	2	3	4	5
<i>MAPE</i>	8,9	12,8	17,2	23,8	27,4	31,5
<i>MASE</i>	0,6	0,43	0,77	0,87	0,95	1,15
godz.	12	13	14	15	16	17
<i>MAPE</i>	16,5	17,8	19,1	24,3	30,1	34,5
<i>MASE</i>	0,77	0,87	0,93	1,24	1,51	1,80
kwiecień						
godz.	0	1	2	3	4	5
<i>MAPE</i>	14,5	17,3	19,0	25,1	27,6	29,8
<i>MASE</i>	0,37	0,69	0,98	1,16	1,72	2,54
godz.	12	13	14	15	16	17
<i>MAPE</i>	17,2	18,9	22,7	26,5	29,6	33,1
<i>MASE</i>	0,68	0,85	1,04	1,20	1,48	1,82

W przypadku obiektów szklarniowych, z racji na istotny wpływ warunków zewnętrznych i małą bezwładność obiektu, zdaniem autora akceptowane różnice w prognozach zapotrzebowania na ciepło, powinny wynosić do 20% warto-

ści zmiennej prognozowanej. Jest to wystarczający poziom błędu, akceptowany z punktu widzenia możliwości dostarczenia strumienia ciepła z systemu grzewczego.

Wartości względnego średniego bezwzględnego błędu procentowego *MAPE* wskazują, że pierwsze 2 – 3 obserwacje w horyzoncie prognozy w miesiącu kwietniu mają poziom akceptowalny, natomiast w miesiącu lutym 3 pierwsze prognozy zapotrzebowania na ciepło.

Wartości błędu *MASE* mniejsze od jedynki wskazują, że prognoza zapotrzebowania na ciepło dla szklarni będzie lepsza niż prognoza uzyskana metodą naiwną. A zatem można stwierdzić, że pierwsze pięć obserwacji w miesiącu lutym w godzinach nocnych przyjmuje poziom akceptowalny, natomiast w porze dziennej trzy pierwsze wartości prognoz ex post zapotrzebowania na ciepło.

Wartości błędu *MASE* dla prognoz w miesiącu kwietniu przyjmują poziom akceptowalny dla trzech obserwacji w porze nocnej oraz dwóch obserwacji w porze dnia.

Średni bezwzględny skalowany błąd *MASE*, z racji na konstrukcję, jest dobrym narzędziem do oceny danych z sezonowością, a zatem pozwala na ocenę dokładności prognoz w przypadku szeregu czasowego nieujemnego, jakim są dane o zużyciu ciepła w oparciu, o które zbudowano model SARIMA.

#### 4. WNIOSKI

Przedstawione wyniki analiz pozwoliły na ocenę dokładności prognoz zapotrzebowania na ciepło w szklarni przy użyciu zaproponowanego modelu SARIMA (2,1,2) (2,0,1)<sup>12</sup>.

W artykule podjęto się odpowiedzi na pytanie, jakie są błędy prognoz i czy model jest stabilny, wykorzystując dane okresu grzewczego od 1 listopada do 30 kwietnia.

Model SARIMA, za wyjątkiem analiz wykonanych w pierwszym miesiącu – listopadzie, zachowuje się stabilnie podczas wykonywania prognoz sekwencyjnych zapotrzebowania na ciepło. Wszystkie parametry modelu są istotne statystycznie.

W ocenie dokładności prognoz, w celu ich lepszego zilustrowania, wykorzystano głównie wartości błędów bezwzględnych. W podjęciu decyzji o ustaleniu dopuszczalnej długości okresu prognozy, zdecydowano się na analizę błędów *MAPE* i *MASE*, które potwierdzają wstępnie przyjęte przypuszczenia o najmniejszym błędzie w zakresie trzech pierwszych obserwacji.

Analizując wartości błędów przedstawionych w Tab. 2 oraz błędów bezwzględnych zilustrowanych graficznie należy stwierdzić, że można zaproponować w przypadku analizowanego obiektu szklarniowego prognozowanie zapotrzebowania na ciepło w dopuszczalnym zakresie trzech obserwacji prognozowanych, przy czym błąd prognozy w większości prognoz ex post zapotrzebowania na ciepło powinien mieścić się w granicach kilkunastu procent.

## PRECISION OF FORECASTING THE HEAT DEMAND IN GREENHOUSE

**Summary:** Short-term heat demand predictions give possibility for increasing efficiency of heat production, reduce fuel consumption and connected with it emission decreasing from combustion products to the atmosphere. The paper presents a problem precision of forecasting heat demand in a greenhouse building using SARIMA methods. Information source for the analysis of time series were operating data of energy consumption.

### Literatura

- [1] ASHRAE Handbook Fundamentals. *Energy Estimating and Modeling Methods*. ASHRAE, Atlanta 2005
- [2] Box, G. E. P., Jenkins, G. M., *Time series analysis*. Holden Day, San Francisco 1970
- [3] Chalabi Z.S., Bailey B.J., Wilkinson D.J., *A-real-time optimal control algorithm for greenhouse heating*. Computers and electronics in agriculture 15 (1996) 1–13
- [4] Ediger V.S., Akar S., *ARIMA forecasting of primary energy demand by fuel in Turkey*. Energy Policy 35 (2007) 1701–1708
- [5] Grabarczyk S., *Prognozowanie zużycia energii cieplnej w szklarniach z ekranami termoizolacyjnymi*. Proceedings of XI International Conf. ACAP&DH. Wrocław-Szklarska Poręba 2005, 175 – 180
- [6] Grabarczyk S., *Prognozowanie zużycia energii cieplnej i zmian temperatury wewnętrznej szklarni z wykorzystaniem sztucznych sieci neuronowych*. Energia i Budynek 12 (2008) 40–45
- [7] Grabarczyk S., *Zastosowanie szeregów czasowych w prognozowaniu zapotrzebowania na ciepło w szklarni*, Building Physics in Theory and Practice (2013) 19–24
- [8] Kendall, M., Ord, J. K., *Time series* (3rd ed.). Griffin, London 1990
- [9] Pankratz, A., *Forecasting with univariate Box-Jenkins models: Concepts and cases*. Wiley, New York 1983
- [10] Sumer K.K., Goktas O., Hepsag A., *The application of seasonal latent variable in forecasting electricity demand as an alternative method*. Energy Policy 37 (2009) 1317–1322
- [11] Vandaele, W., *Applied time series and Box-Jenkins models*. Academic Press, New York 1983
- [12] Wojdyga K., *Prognozowanie zapotrzebowania na ciepło w miejskich systemach ciepłowniczych*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2007
- [13] Zhu S., Wang J., Zhao W., Wang J., *A seasonal hybrid procedure for electricity demand forecasting in China*. Applied Energy 88 (2011) 3807–3815