



Grzegorz BARTNICKI¹, Bogdan NOWAK¹

Model ARIMA w prognozowaniu zużycia gazu w cyklach miesięcznych

Streszczenie: Potraktowanie zużycia paliwa w kotłowni jako szeregu czasowego daje możliwość użycia do analizy tego zjawiska narzędzi odpowiednich do przetwarzania takich danych. Jednym z nich są modele ARIMA. W artykule zaproponowano wykorzystanie tego typu modeli do prognozowania miesięcznego zużycia gazu w kotłowni pracującej na potrzeby ogrzewania i przygotowania ciepłej wody. Kotłownia zasila w ciepło grupę budynków mieszkalnych. Na podstawie zebranych danych pomiarowych wytypowano trzy konkretne modele, dla których przeprowadzono ocenę trafności prognozy. Obliczenia i analizy zostały przeprowadzone w środowisku R przy zastosowaniu pakietów *forecast* oraz *ggplot2*. Wykazana została dobra jakość uzyskanych prognoz, potwierdzająca przydatność zaproponowanych narzędzi analitycznych. W podsumowaniu artykułu wskazano również, do jakich celów można wykorzystać uzyskane w ten sposób prognozy. Mogą one być przydatne do diagnostyki poprawności działania źródła ciepła. Zarejestrowanie zużycia paliwa na poziomie poważnie odbiegającym od prognozy powinno być jednoznaczną przesłanką do niezwłocznego przeprowadzenia diagnozy stanu pracy kotłowni i całego systemu zaopatrzenia w ciepło oraz wyjaśniania przyczyny tej różnicy. W ten sposób można doprowadzić do wykrycia nieprawidłowości w działaniu systemu zaopatrzenia w ciepło, na długo przed stwierdzeniem ich tradycyjnymi metodami. Prognoza zużycia gazu jest też przydatna do optymalizacji zarządzania finansami zarządcy nieruchomości odpowiedzialnego za eksploatację kotłowni. Na tej podstawie mogą być planowane opłaty eksploatacyjne lub też operacje finansowe z wykorzystaniem okresowej nadwyżki kapitału, pochodzącej z różnicy pomiędzy wydatkami na zakup paliwa a opłatami za ogrzewanie.

Słowa kluczowe: miesięczne zużycie gazu, szereg czasowy, kotłownia gazowa

Forecasting natural gas consumption in monthly cycles with the ARIMA model

Abstract: Describing the gas boiler fuel consumption as a time series gives the opportunity to use tools appropriate for the processing of such data to analyze this phenomenon. One of them are ARIMA models. The article proposes this type of model to be used for predicting monthly gas consumption in a boiler room working for heating and hot water preparation. The boiler supplies heat to a group of residential buildings. Based on the collected data,

¹ Politechnika Wroclawska, Katedra Klimatyzacji, Ogrzewnictwa, Gazownictwa i Ochrony Powietrza, Wrocław; e-mail: grzegorz.bartnicki@pwr.edu.pl

three specific models were selected for which the forecast accuracy was assessed. Calculations and analyses were carried out in the R environment using "forecast" and "ggplot2" packages. A good quality of the obtained forecasts has been demonstrated, confirming the usefulness of the proposed analytical tools. The article summary also indicates for what purposes the forecasts obtained in this way can be used. They can be useful for diagnosing the correct operation of a heat source. Registering fuel consumption at a level significantly deviating from the forecast should be a signal to immediately diagnose the boiler room and the heat supply system and to explain the reason for this difference. In this way, it is possible to detect irregularities in the operation of the heat supply system before they are detected by traditional methods. The gas consumption forecast is also useful for optimizing the financial management of the property manager responsible for the operation of the boiler room. On this basis, operating fees or financial operations with the use of periodic surplus capital may be planned.

Keywords: monthly gas consumption, time series, gas boiler room

Wprowadzenie

Budownictwo i eksploatacja budynków (budynki mieszkalne, użyteczności publicznej, przemysłowe, rolnicze) są wskazane w (Górzyński 2012) jako najbardziej energochłonny dział polskiej gospodarki, zużywający ok. 50% energii końcowej. W tym bilansie dominujący udział ma zużycie energii zapewniającej funkcje użytkowe budynków. Jest ono wynikiem m.in. warunków klimatycznych, w jakich budynki są eksploatowane. Przyczyn nadmiernego zużycia energii należy jednak poszukiwać również w innych czynnikach, co potwierdzić może porównanie do innych krajów położonych w podobnych lub mniej korzystnych regionach geograficznych. Chociaż od co najmniej kilkunastu lat podejmowane są działania ukierunkowane na ograniczenie energochłonności budownictwa, to proces ten będzie długotrwały i jest trudny do zrealizowania. Nie dotyczy bowiem wyłącznie nowych obiektów, którym łatwo jest narzucić określone wymagania czy warunki, ale znacząca większość użytkowanych obiektów już istnieje i charakteryzuje się cechami odbiegającymi od obowiązujących obecnie kryteriów. Przedmiotem współczesnych badań naukowych i analiz są zatem nie tylko nowe technologie i rozwiązania przeznaczone dla dopiero projektowanych budynków, ale również stan istniejącej już infrastruktury oraz sposoby ograniczenia jej energochłonności (Doty 2007; Harvey 2006; Thumann 2007). Ich wynikiem są nie tylko rekomendacje czy zalecenia wskazujące na konieczność podjęcia określonego działania czy modernizacji, ale również metody i narzędzia matematyczne ułatwiające opis badanych zjawisk, umożliwiające identyfikowanie związków i zależności pomiędzy istotnymi cechami obiektów oraz zachodzących w nich procesów i zjawisk. Mogą to być modele zbudowane dla realizacji określonej potrzeby czy opisu konkretnej instalacji (Zaleski 2004; Nowak i Zaleski 1995), ale coraz częściej wykorzystuje się adaptację uniwersalnych modeli (dostępnych w postaci oprogramowania) na potrzeby konkretnych zastosowań (Malska i Wachta 2015; Brabec i in. 2008; Ozmen i in. 2018). Szczególną grupą takich modeli są modele prognostyczne. Mają one pomóc określać, w jaki sposób będzie się kształtował dany proces lub zjawisko w przyszłości, z jak największą trafnością (dokładnością) tej prognozy. Tego typu modele nie tylko są przydatne w ekonomii, makro gospodarce, analizie giełdowej, ale również w technice, w tym energetyce. Informacja o prognozie światowego zużycia energii czy jego strukturze paliwowej na kolejne dekady (Gałuszka i Paruch 2011; Górzyński 2012; Harvey 2006) ma nie tylko określać sytuację, ale przede wszystkim ułatwić decyzję

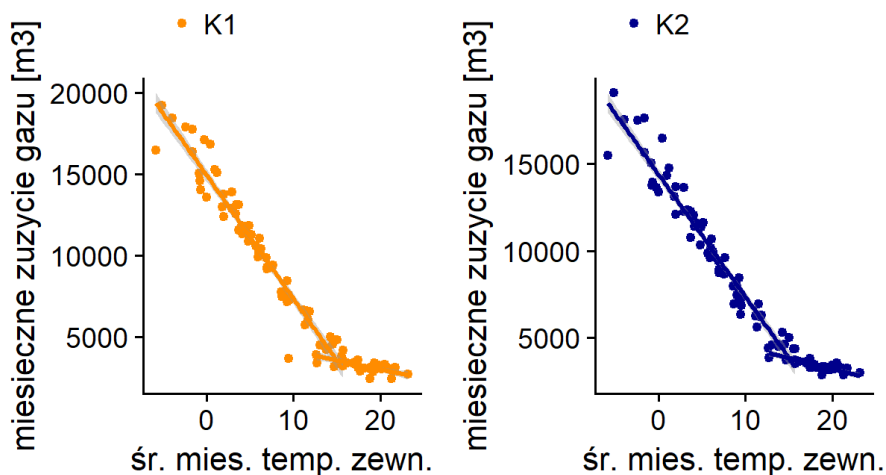
o wyborze źródła energii pierwotnej (zarówno w skali makro, jak i pojedynczego źródła ciepła), której skutki i trafność można oceniać dopiero po latach. Prognozy dotyczyć mogą też dużo mniejszej skali i perspektywy czasowej, biorąc pod uwagę np. precyzję zapewnienia warunków dostawy czy zarządzanie popytem. W tego typu narzędziach matematycznych duże znaczenie ma identyfikacja czynników mogących mieć wpływ na przebieg procesu czy zjawiska oraz ich zależność. Z punktu widzenia użytkownika znaczenie ma łatwość zbudowania i wykorzystania modelu oraz trafność prognozy.

W artykule przedstawiono możliwości wykorzystania modelu ARIMA do prognozowania w cyklach miesięcznych zużycia gazu w kotłowni gazowej zasilającej w ciepło grupę budynków mieszkalnych. Kotłownia zasila odbiorców w ciepło na potrzeby ogrzewania oraz przygotowania ciepłej wody użytkowej. Ciąg obserwacji w kolejnych jednostkach czasu (miesiącach) tworzący szereg czasowy charakteryzuje się określonym trendem i sezonowością. Te cechy pozwoliły na użycie zaproponowanej metody do takiej właśnie analizy.

1. Zużycie gazu ziemnego a warunki pogodowe

Zużycie paliwa przez źródło ciepła w systemie zaopatrzenia w ciepło bezpośrednio odzwierciedla zużycie energii w instalacjach budynku, łącznie ze stratami przemian i dystrybucji. Zużycie ciepła na potrzeby ogrzewania i wentylacji zależne jest od temperatury zewnętrznej. Ma ono zatem charakter sezonowy, ale tylko w teorii jest to zależność liniowa. Zależy również od indywidualnie utrzymywanej w pomieszczeniach temperatury wewnętrznej oraz od intensywności wentylacji pomieszczeń. Inaczej jest ze zużyciem ciepła w postaci ciepłej wody użytkowej (c.w.u.), które ma dużo bardziej losowy charakter i zależy od indywidualnych zachowań użytkowników budynku oraz ich liczby (Zaleski 2004; Nowak i Zaleski 1995). W budownictwie mieszkaniowym wielolokalowym kotłownia (źródło ciepła) jest najczęściej układem dwufunkcyjnym, który zapewnia ogrzewanie oraz dostawę ciepła do układu przygotowania c.w.u. Sumaryczne zużycie paliwa jest zatem superpozycją wpływu warunków pogodowych oraz preferencji i oczekiwań użytkowników. Wynika też z konkretnej konstrukcji budynku, jego izolacyjności i powierzchni przegród zewnętrznych, ustalonych na etapie projektu.

Dla zilustrowania zależności zużycia gazu przez dwufunkcyjną kotłownię gazową zasilającą w ciepło wielorodzinny budynek mieszkalny od temperatury zewnętrznej przedstawiono na rys. 1 zależność pomiędzy średnią miesięczną temperaturą zewnętrzną i miesięcznym zużyciem gazu. Wykorzystano w tym celu wyniki pomiarów przeprowadzonych w dwóch jednakowych kotłowniach dwufunkcyjnych (K1 i K2), każda z nich zasila w ciepło trzy budynki należące do tej samej wspólnoty mieszkaniowej. Średnią miesięczną temperaturę zewnętrzną wyznaczono w oparciu o pomiary jednoczesne udostępnione przez IMGW-PIB. Pomiary zużycia gazu wykonano w okresie od 2010 do 2017 roku. Dodatkowo na rysunku zaznaczono, dla każdego ze źródeł ciepła odrębnie, dwie linie regresji. Jedna z nich została wyznaczona dla miesięcy zimowych (styczeń–maj oraz październik–grudzień), a druga – dla okresu letniego (czerwiec–wrzesień).



Rys. 1. Zależność miesięcznego zużycia gazu ziemnego w kotłowni gazowej K1 i K2 od średniej temperatury zewnętrznej (w latach 2010–2017)

Fig. 1. The impact of the average external temperature (in 2010–2017) on monthly natural gas consumption in the gas boiler rooms (K1 and K2)

W tabeli 1 zestawiono wyznaczone wartości współczynników korelacji Pearsona dla zależności pomiędzy miesięcznym średnim zużyciem gazu i średnią miesięczną temperaturą zewnętrzną. Zarówno analiza graficzna (rys. 1), jak i współczynniki korelacji (tab. 1) wskazują na istotną zależność (liniową) pomiędzy zużyciem gazu w kotłowni a średnią temperaturą zewnętrzną. W okresie letnim charakter zależności jest jednak inny niż w tzw. sezonie grzewczym (tj. gdy występują potrzeby grzewcze). W skali miesiąca średnie zużycie ciepłej wody w budynku jest w miarę stabilne, a latem zużycie gazu związane jest tylko z tym

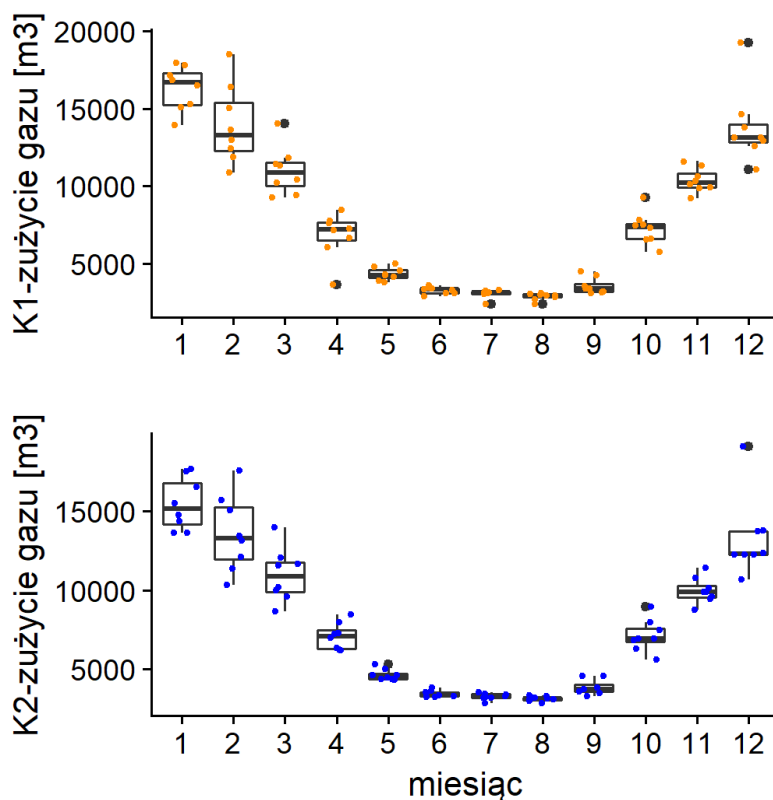
TABELA 1. Współczynnik korelacji Pearsona dla zależności pomiędzy miesięcznym zużyciem gazu a średnią temperaturą zewnętrzną (dane z lat 2010–2017)

TABLE 1. Pearson's correlation coefficient for the relation between monthly gas consumption and average external temperature (data from 2010–2017)

Rok	A5	A6
2010	-0,954	-0,964
2011	-0,981	-0,975
2012	-0,979	-0,977
2013	-0,974	-0,971
2014	-0,960	-0,954
2015	-0,951	-0,949
2016	-0,975	-0,985
2017	-0,973	-0,980

sposobem zużycia ciepła. Linia regresji jest zatem prawie pozioma. Wahania temperatury wody zimnej (wynikające z wahań temperatury zewnętrznej) czy wahania temperatury wody ciepłej są raczej pomijalne, większy wpływ mogą mieć wahania wartości opałowej paliwa (Bartnicki i Nowak 2018).

Na rysunku 2 dla każdej kotłowni przedstawiono punkty pomiarowe odpowiadające kolejnym miesiącom roku. Dla sporządzenia wykresu wykorzystano dane pomiarowe z lat 2010–2017. Widoczna jest duża stabilność zużycia gazu w miesiącach letnich. Większe zróżnicowanie obserwowane jest dla sezonu grzewczego. Jest to zbieżne z wcześniejszą analizą. Zużycie gazu w okresie od maja do września zależy od temperatury zewnętrznej (rys. 1), ale linia regresji wyznaczona dla tej części roku wskazuje ilościowo na dużo mniejszy wpływ tej zmiennej (niewielki kąt nachylenia linii regresji). Na rysunku 2 wyodrębniono dodatkowo wartości (czarne punkty), które spełniają formalne warunki uznania za dane



Rys. 2. Zużycie gazu w kotłowniach K1 i K2 w poszczególnych miesiącach (dane z lat 2010–2017). Oznaczenia: pole prostokąta – wartości pomiędzy pierwszym a trzecim kwantylem, pozioma linia czarna – mediana, dodatkowo oznaczono punkty odstające – ponad $1,5 \times$ wartość trzeciego kwantyla

Fig. 2. Gas consumption in boiler rooms (K1 and K2) in the following months of the year (data from 2010–2017). Markings: field of the rectangle – values between the 1st and 3rd quantiles, horizontal black line – median, additionally marked outliers – over $1,5 \times$ value of the 3rd quantile

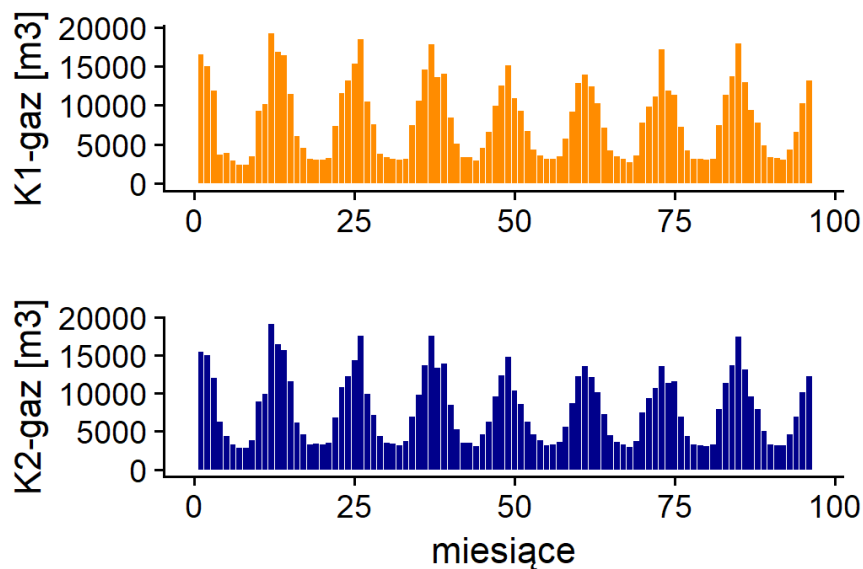
odstające. Dla kotłowni K1 są to pomiary zaobserwowane w marcu, październiku oraz grudniu, a dla kotłowni K2 – w październiku oraz grudniu.

2. Miesięczne zużycie gazu jako szereg czasowy

Przy tworzeniu modeli opisujących zużycia ciepła w budynku czy odpowiadające mu zużycie gazu w źródle ciepła (Górzyński 2012) zazwyczaj wykorzystuje się temperaturę zewnętrzną jako jedną z podstawowych zmiennych niezależnych. Jest to podejście uzasadnione i w pełni naturalne. Aktualnie pozyskanie historycznych danych meteorologicznych w danej lokalizacji jest dużo prostsze niż kilkanaście lat temu (m.in. dzięki zbudowaniu w Polsce przez IMGW-PIB na początku XXI w. nowoczesnego, zautomatyzowanego systemu obserwacji, gromadzenia i przetwarzania danych pomiarowych, wraz z bazami danych operacyjnych i historycznych). Dokładne modele prognozujące warunki pogodowe są już jednak oferowane na zasadach komercyjnych, co ogranicza ich dostępność dla drobnych podmiotów, takich jak właściciele czy zarządcy pojedynczych budynków, spółdzielnie lub wspólnoty mieszkaniowe. Do budowy modeli prognozujących zużycie gazu zasadne byłoby tymczasem zastosowanie takich właśnie danych. Poza samym dostępem do prognozy danych meteorologicznych, odrębnym aspektem jest też możliwość pogorszenia zdolności predykcyjnych modelu, który bazowałby na danych prognostycznych. Prognozy pogody dla okresu kilku lub kilkunastu dni nie są już tak precyzyjne, a ich trafność maleje wraz z wyprzedzeniem czasowym, którego dotyczą. Tymczasem z punktu widzenia zarządzania kosztami eksploatacji źródła ciepła czy systemu grzewczego budynku użyteczne mogłyby być przede wszystkim modele dotyczące prognoz zużycia gazu dla okresów od jednego do kilku miesięcy.

Analiza zgromadzonych danych pomiarowych (rys. 1 i 2) potwierdziła, że miesięczne zużycie gazu w kotłowni można zdefiniować jako szereg czasowy (ciąg obserwacji pewnego zjawiska w kolejnych jednostkach czasu – miesiącach), z trendem i sezonowością. Do wnioskowania o przyszłych wartościach (tj. prognozowania) mogą więc być również wykorzystywane metody służące do analiz szeregów czasowych. Opis zużycia paliwa w postaci szeregu czasowego daje możliwość zastosowania narzędzi właściwych do obróbki tego rodzaju danych. Jednym z nich są modele ARIMA. W artykule przedstawiona została ocena ich dokładności i skuteczności w wykorzystaniu do prognozowania zużycia gazu kotłowni pracującej na potrzeby ogrzewania i przygotowania c.w.u. Model ARIMA (p , d , q) charakteryzują trzy wartości: p – ilość parametrów autoregresyjnych, d – ilość parametrów średniej ruchomej oraz q – rząd różnicowania. Budowa modelu składa się z trzech etapów. W pierwszym następuje identyfikacja liczby oraz typu parametrów modelu. W drugim etapie dokonywana jest estymacja wartości parametrów. W etapie diagnozy następuje ocena wybranego modelu i trafności prognozy (Malska i Wachta 2015).

Miesięczne zużycie gazu w kotłowni dwufunkcyjnej podlega dwunastomiesięcznym cyklom sezonowym (rys. 3). Jest to jednoznaczne dla zastosowania różnicowania z opóźnieniem $s = 12$. Założenie to wyeliminuje również trend liniowy, o ile taki był obecny w danych.



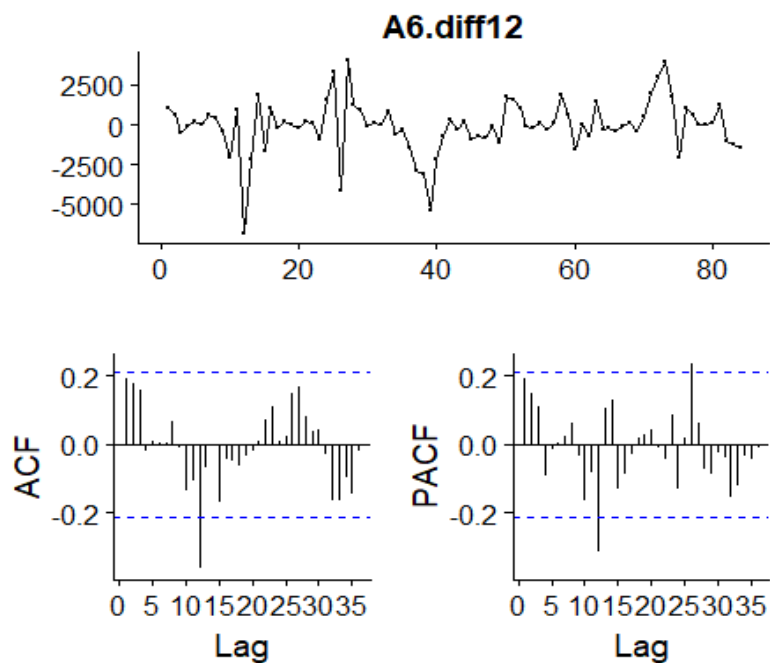
Rys. 3. Miesięczne zużycie gazu ziemnego w kotłowniach K1 i K2 w 96 okresach rozliczeniowych (dane z lat 2010–2017)

Fig. 3. Monthly natural gas consumption in the gas boiler rooms (K1 and K2) in 96 accounting periods (data from 2010–2017)

Na wykresie (rys. 4) przedstawiono szereg czasowy po zróżnicowaniu z opóźnieniem $s = 12$ oraz wykresy funkcji ACF oraz PACF. Analiza uzyskanych wyników wskazuje, że nie ma większych zastrzeżeń co do stacjonarności przekształconego szeregu. Mając ustalony parametr sezonowości s , wnioskujemy o wartościach parametrów d i D jako równych 0 przyszłego modelu SARIMA $(p, d, q)(P, D, Q)_s$ (przekształcony szereg wykazuje stacjonarność). Dalsze rozważania mogą zatem dotyczyć szczególnego przypadku modelu ARIMA (p, d, q) , czyli modelu ARMA (p, q) .

W przypadku modeli mieszanych (ARMA) trudnością może być jednoznaczne zidentyfikowanie parametrów p i q w oparciu o wykresy ACF i PACF. Analiza tychże wykresów (rys. 4) wskazuje na $q = 12$ oraz $p = 12$ dla modelu sezonowego $s = 12$. Zaproponowano zatem model.2 w oparciu o analizę ACF i model.3 – w oparciu o PACF. Zazwyczaj jednak modele ARMA wymagają dużo niższych rzędów p i q w porównaniu z modelami AR oraz MA – zaproponowano zatem model.1. Model.1 został wytypowany w oparciu o wynik automatycznego wyboru modelu przez pakiet *forecast*. Ostatecznie zazwyczaj do identyfikacji rzędów p i q w modelu ARMA wykorzystuje się kryteria oceniające dobroć dopasowania modelu, takie jak AIC, AICC, BIC lub inne. Dlatego do wyboru modelu ARIMA należałoby zbadać większą grupę i wybrać na podstawie kryteriów oceniających. W przeprowadzanej analizie ten typ modeli jest tylko przykładem możliwości wykorzystania.

Mając na uwadze te przesłanki, do dalszej oceny wytypowano trzy konkurencyjne modele:



Rys. 4. Szereg po zróżnicowaniu z opóźnieniem $s = 12$ wraz z funkcjami ACF oraz PACF

Fig. 4. A series after delay with differentiation $s = 12$ together with the ACF and PACF functions

- ARIMA(3,0,1) – model.1
- ARIMA(0,0,12)(0,0,0)₁₂ – model.2
- ARIMA(12,0,12)(0,0,0)₁₂ – model.3

Wszystkie obliczenia i analizy zostały przeprowadzone w środowisku R przy zastosowaniu pakietów *forecast* oraz *ggplot2*.

TABELA 2. Wartości parametrów informacyjnych dla zaproponowanych modeli

TABLE 2. The parameters values for the proposed models

	AIC	AICC	BIC
model.1	1708,283	1709,227	1723,669
model.2	1746,025	1751,211	1781,926
model.3	1687,328	1692,513	1723,229

Nie ma jednoznacznej odpowiedzi, które kryterium informacyjne jest kluczowe przy wyborze modelu. Nie ma też wartości granicznej, od której można uznać model za dobry. I jeszcze jedno – nie ma wartości granicznej, od której można uznać model za dobry. Ta procedura działa w ten sposób, że przy pomocy kryterium informacyjnego porównuje się kilka modeli i wybiera ten, który ma najniższą wartość. W tym konkretnym przypadku zaproponowany model.3 uzyskał najniższe wartości we wszystkich kryteriach spośród wszystkich badanych modeli, a zatem należy uznać go za najlepszy z tej grupy.

Dla wszystkich modeli przeprowadzono diagnostykę w oparciu o analizę reszt, przy zastosowaniu narzędzi graficznych i testów statystycznych. Na rysunku 5 przedstawiono wykresy diagnostyczne dla model.3, w tym autokorelację reszt modelu (*ACF of Residuals*). Pokazuje on, że dla dowolnego opóźnienia ($\text{lag} > 0$) autokorelacja reszt zanika.

TABELA 3. Wartości miar dopasowania modelu

TABLE 3. The values of the model fit measures

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
model.1	20,324	1 627,545	1 233,908	-2,724	19,564	0,564	-0,037
model.2	-12,387	1 714,132	1 212,759	-8,469	18,404	0,554	0,027
model.3	-19,587	1 314,703	959,983	-1,414	13,793	0,439	-0,004

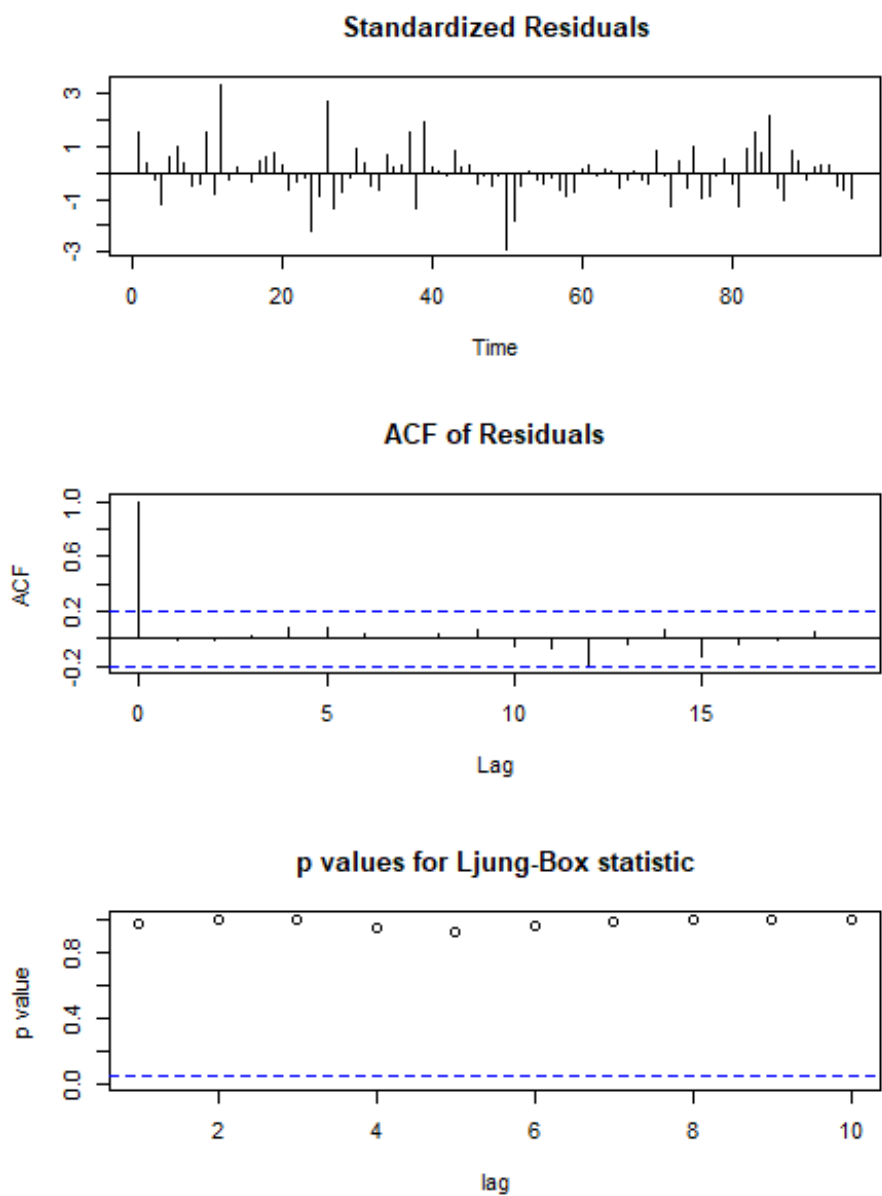
Przykładowo dla model.3 wynik testu Shapiro-Wilka nie pozwala przyjąć hipotezy o zgodności rozkładu reszt z rozkładem normalnym ($p\text{-value} = 0.003871 < 0.005$). Jest to istotny fakt w kontekście ewentualnych procedur wnioskowania statystycznego, które bazują istotnie na założeniu o normalności danych. Na wykresie normalności reszt (rys. 6) praktycznie większość punktów (reszt) leży bardzo blisko linii, co oznacza, że reszty te podlegają rozkładowi normalnemu.

Na kolejnych wykresach przedstawiono dopasowanie modeli do danych pomiarowych (zbiór treningowy), wartości prognozowane oraz wartości dla dwóch miesięcy (zbiór testowy). Przedstawione zostały również wartości miar dokładności predykcji (RMSE, MAE, MAPE, MASE).

W oparciu o zaprezentowane w tabeli 4 wyniki zauważyć można, że najlepszy wydaje się być model.3. Dla trzech miesięcy do przodu predykcja jest dokładna (błąd 25%). Dla kolejnych miesięcy błąd prognozy znacząco rośnie. Trzeba pamiętać, że w marcu 2018 r. (99 okres) wystąpiły nietypowe warunki pogodowe – tak niskich temperatur w tym miesiącu nie było ciągu ostatnich kilku lat.

Podsumowanie i wnioski


Przedstawiona analiza wskazuje na dobrą jakość prognoz miesięcznego zużycia gazu w kotłowni dwufunkcyjnej przy wykorzystaniu do niej modelu ARIMA. Rozwój metod numerycznych i coraz większa dostępność narzędzi statystycznych do obróbki danych pomia-



Rys. 5. Wykresy diagnostyczne dla model.3


Fig. 5. Diagnostic charts for model.3

rowych pozwala na zmianę dotychczasowego podejścia zarządców budynków, operatorów źródeł ciepła czy przedsiębiorstw energetycznych do zarządzania systemem zaopatrzenia w ciepło. Wykorzystanie wyłącznie danych historycznych do rozliczania kosztów i plano-



Rys. 6. Analiza normalności i histogram reszt wyznaczonych w oparciu o model.3

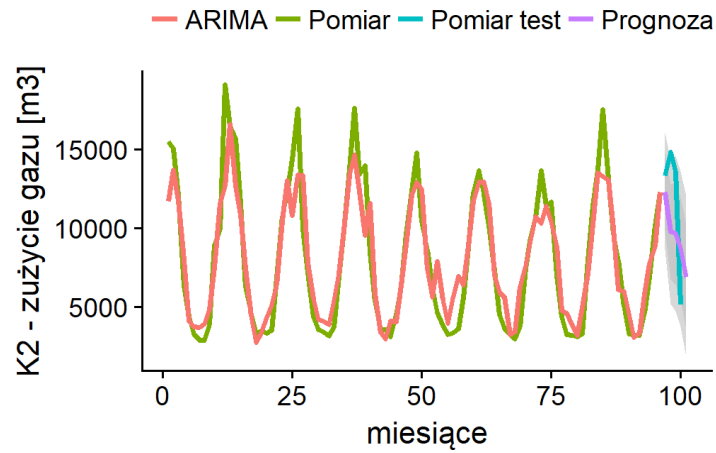
Fig. 6. The residual nodities chart and histogram determined on the basis of model.3



Rys. 7. Dane pomiarowe, dopasowanie oraz zdolności predykcyjne model.1


Fig. 7. Measurement data, fit and predictive capability of model.1

wania działalności powinno być uzupełnione o planowanie opłat za ogrzewanie i energię oraz przychodów i kosztów eksploatacji systemu w oparciu o modele prognostyczne, np. stosowane do analizy szeregów czasowych. Znaczenie mogą mieć również w samym diagnozowaniu działania systemu. W przypadku gdy faktyczne zużycie ciepła (paliwa) w kolejnym okresie rozliczeniowym okaże się zasadniczo różne od prognozowanego, konieczne



Rys. 8. Dane pomiarowe, dopasowanie oraz zdolności predykcyjne model.2

Fig. 8. Measurement data, fit and predictive capability of model.2



Rys. 9. Dane pomiarowe, dopasowanie oraz zdolności predykcyjne model.3

Fig. 9. Measurement data, fit and predictive capability of model.3

staje się wyjaśnienie tej różnicy oraz ocena, czy nie jest to czasem efekt nieuzasadnionego pogorszenia efektywności energetycznej (wzrost strat ciepła). Jeśli nietypowość warunków pogodowych nie usprawiedliwiają zaobserwowanej rozbieżności, powinien być to jednoznaczny sygnał do bardziej szczegółowej kontroli całego systemu zaopatrzenia w ciepło oraz poszczególnych jego elementów (Baldacci i in. 2016). Poważna różnica między war-

TABELA 4 Dane pomiarowe dla 97–100 okresów rozliczeniowych oraz wartości predykcyjnych uzyskanych w oparciu o zaproponowane modele. Dodatkowo określono dokładność oszacowań

TABLE 4. Measurement data for 97–100 accounting periods and prediction values obtained on the basis of the proposed models. In addition, the accuracy of the estimates was determined

Okres rozliczeniowy	Dane testowe m ³	model.1		model.2		model.3	
		m ³	%	m ³	%	m ³	%
97	13 328	13 179	101	12 308	108	14 327	093
98	14 843	12 685	117	9 773	152	13 050	114
99	13 625	10 972	124	96 612	141	10 791	126
100	5 099	8 536	167	8 662	170	8 051	158
101	–	6 050	–	6 896	–	5 282	–

tościami prognozowanymi a rzeczywistymi może bowiem świadczyć o stanach awaryjnych (w szczególności jeśli nie można jej wyjaśnić warunkami meteorologicznymi albo innymi przyczynami zewnętrznymi).

Modele prognostyczne powinny być również wykorzystywane do planowania budżetu. Wspólnoty mieszkaniowe (również spółdzielnie mieszkaniowe) finansują koszty zakupu paliwa zwykle w formie zaliczek, których wysokość jest stała w ciągu roku. Rozliczenie z odbiorcami ciepła następuje w cyklach pół- lub rocznych, po rozliczeniu całego sezonu. Stałe w ciągu roku obciążenie kosztami za ogrzewanie nie odpowiada rzeczywistej zmienności tych kosztów w czasie. W okresie letnim powstaje u zarządcy nieruchomości nadwyżka finansowa w pozycji planu gospodarczego właściwej dla kosztów zaopatrzenia w ciepło. Prognozy zużycia paliwa pozwalają szacować przyszłe koszty jego zakupu. Tym samym możliwe jest skuteczniejsze pod względem zysków zarządzanie nadwyżką np. poprzez trafne ustalenie wielkości i czasu trwania lokaty bankowej. Inną możliwością jest rezygnacja z takiej nadwyżki finansowej na rzecz miesięcznego zróżnicowania opłat za ciepło oraz cen jednostkowych.

Literatura

- Baldacci i in. 2016 – Baldacci, L., Golfarelli, M., Lombardi, D. i Sami, F. 2016. Natural gas consumption forecasting for anomaly detection. *Expert Systems With Applications* No. 62, s. 190–201.
- Bartnicki, G. i Nowak, B. 2018. Zmienność poboru paliwa gazowego w lokalnych źródłach ciepła obsługujących grupy budynków mieszkalnych. *Zeszyty Naukowe Instytutu Gospodarki Surowcami Mineralnymi i Energią PAN* nr 102, s. 37–50.
- Brabec i in. 2008 – Brabec, M., Konar, O., Pelikan, E. i Maly, M. 2008. A nonlinear mixed effects model for the position of natural gas consumption by individual customers. *International Journal of Forecasting* No. 24, s. 659–678.
- Doty, S. 2007. Commercial Energy Auditing. Reference Handbook. *The Fairmont Press*, Lilburn.
- Franco, A. 2016. Natural gas consumption and correlation with the uses of thermal energy: Analysis of the Italian case. *Journal of Natural Gas Science and Engineering* No. 31, s. 703–714.

- Gałaszka, M. i Paruch, J. red. 2011. *Energetyka gazowa*. Tarbonus, Kraków–Tarnobrzeg.
- Górczyński, J. 2012. Podstawy analizy energetycznej obiektów budowlanych. Warszawa: Oficyna Wydawnicza Politechniki Warszawskiej.
- Harvey, L.D.D. 2006. *A Handbook on Low-Energy Buildings and District-Energy Systems*. Earthscan, London – Sterling VA.
- Ozmen i in. 2018 – Ozmen, A., Yilmaz, Y. i Weber, G.W. 2018. Natural gas consumption forecast with MARS and CMARS models for residential users. *Energy Economics* No. 70, s. 357–381.
- Thumann, A. i Younger, W.J. 2007. *Handbook of Energy Audits*. The Fairmont Press, Lilburn.
- Malska, W. i Wachta, H. 2015. Wykorzystanie modelu Arima do analizy szeregu czasowego. *Zeszyty Naukowe Politechniki Rzeszowskiej* 292, *Elektrotechnika* 34, RUTJEE, z. 34(3), s. 23–30.
- Nowak, B. i Zaleski, J. 1995. Ogólny model procesu poboru ciepłej wody użytkowej dla wielorodzinnego budownictwa mieszkaniowego. *Archiwum Energetyki* t. 24, nr 1/2.
- Zaleski, J. 2004. *Modele stochastyczne i symulacja komputerowa. Zastosowanie do systemów zaopatrzenia w wodę*. Warszawa: PWN.