

Joanna Chrałońska, Joanicjusz Nazarko  
Politechnika Białostocka

## ZASTOSOWANIE MODELI ARIMA W PROGNOZOWANIU PRZYCHODÓW ZE SPRZEDAŻY NA PRZYKŁADZIE PRZEDSIĘBIORSTWA HANDLOWEGO TYPU CASH & CARRY

### 1. Wprowadzenie

Prognoza sprzedaży odgrywa szczególną rolę w zarządzaniu przedsiębiorstwem. Jest ona punktem wyjścia do przewidywania większości pozycji kształtujących poziom wyniku finansowego w każdej firmie. Prognoza sprzedaży jest w szczególności podstawą do tworzenia planu biznesowego, alokacji środków i określenia wielkości zapasów. Wykorzystywana jest również do określenia przyszłych potrzeb finansowych przedsiębiorstwa.

Konstrukcja prognozy sprzedaży, tak jak i innych rodzajów prognoz, jest procesem wieloetapowym. Przebiega według pewnego ogólnego schematu postępowania prognostycznego. Do prognozowania sprzedaży stosuje się metody zarówno ilościowe, jak i heurystyczne. Zastosowanie konkretnych metod wynika ze specyfiki rynku i przyjętych przesłanek prognostycznych. Podstawowym kryterium, które brane jest pod uwagę przy wyborze metody, jest oczekiwana trafność prognozy, koszt jej opracowania i wdrożenia oraz łatwość zastosowania.

W artykule przedstawiono metodologię budowy modeli ARIMA (*Autoregressive Integrated Moving Average*) oraz ich wykorzystanie do prognozowania szeregów jednowymiarowych. Wykorzystano jedno z ogólnie stosowanych podejść do budowy modeli ARIMA, zaproponowane przez Boxa i Jenkinsa.

## 2. Modele ARIMA w analizie szeregów czasowych

Modele ARIMA, czyli scałkowane procesy autoregresji i średniej ruchomej, są bardzo ogólną klasą szeregów czasowych. Ich budowa oparta jest na zjawisku autokorelacji. Mogą być one stosowane do modelowania stacjonarnych szeregów czasowych lub szeregów niestacjonarnych sprowadzalnych do stacjonarnych. Wyróżnia się trzy podstawowe rodzaje modeli tej klasy: modele autoregresji (AR), modele średniej ruchomej (MA) oraz modele mieszane autoregresji i średniej ruchomej (ARMA). Symbol I użyty w nazwie modelu wskazuje, że szereg czasowy poddany został operacji różnicowania.

Do zapisu postaci modelu ARIMA używa się uniwersalnej notacji określającej rząd poszczególnych składowych modelu: (autoregresji -  $p$ , różnicowania -  $d$ , średniej ruchomej -  $q$ ).

Najbardziej ogólną postać modelu ARIMA można zapisać jako ARIMA

$$\phi(B)\Phi(B^s)(1-B^s)^d Y_t = c + \theta(B)\Theta(B^s)e_t, \quad t = 1, 2, \dots, n, \quad (1)$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (1.1)$$

$$\Phi(B) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps} \quad (1.2)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (1.3)$$

$$\Theta(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs} \quad (1.4)$$

( $p, d, q$ )x( $P, D, Q$ )<sub>s</sub> lub w postaci rozwiniętej:

przy czym:

gdzie:  $\phi, \Phi$  - parametr modelu autoregresji,

$B$  - operator przesunięcia wstecz,

$s$  - liczba sezonów w okresie,

$c$  - stała,

$\theta, \Theta$  - parametr modelu średniej ruchomej,

$e_t$  - błąd (reszta) modelu w okresie lub momencie  $t$ .

Proces budowy modelu można ująć w 3 zasadnicze fazy: identyfikację, estymację i testy oraz zastosowanie.

W fazie pierwszej następuje wstępna identyfikacja cech analizowanego szeregu czasowego. Podejmowana jest decyzja o potrzebie transformacji danych w celu stabilizacji wariancji i/lub o różnicowaniu szeregu w celu stabilizacji średniej. Dla szeregu stacjonarnego dokonuje się identyfikacji potencjalnych jego modeli poprzez badanie funkcji autokorelacji (ACF) i autokorelacji cząstkowej (PACF).

W fazie drugiej szacowane są parametry wybranych modeli. Ostateczny wybór modelu następuje zazwyczaj na podstawie analizy kilku kryteriów, tj. istotności parametrów modelu, błędu średniokwadratowego, kryterium informacyjnego (np. AIC - *Akaike's Information Criterion*, BIC - *Bayesian Information Criterion* lub fPE - *Final Prediction Error*).

Wybrany model poddany jest następnie sprawdzeniu diagnostycznemu. Podstawą diagnostyki jest analiza własności szeregu reszt modelu. Jeżeli reszty modelu są procesem białego szumu, nie występują znaczące wartości funkcji ACF lub

PACF szeregu reszt modelu, model może zostać zastosowany do prognozowania. W przeciwnym wypadku należy wrócić do fazy drugiej i wybrać inny model lub do fazy pierwszej, dokonując ponownej identyfikacji modelu.

W fazie trzeciej następuje wykorzystanie modelu do sporządzenia prognozy, czyli jego implementacja.

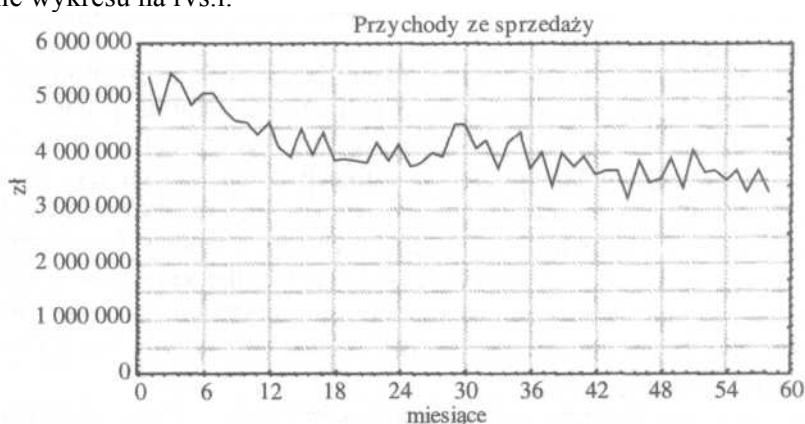
### 3. Zadanie prognostyczne

W artykule dokonano analizy szeregu czasowego przychodów ze sprzedaży dla jednej z filii przedsiębiorstwa handlowego będącego siecią hurtowni spożywczych. Oddział ten prowadzi działalność w formie cash & carry, tj. sprzedaży gotówkowej w samoobsługowych halach sprzedaży, obsługujących podmioty gospodarcze. Charakteryzuje go znaczne zróżnicowanie asortymentowe (ok. 7000 artykułów) i duża liczba odbiorców (ok. 5000). Terytorialne i organizacyjne wyodrębnienie poszczególnych oddziałów spółki umożliwia naturalny podział przedsiębiorstwa na jednostki budżetowe, w których istnieje możliwość przygotowania prognozy przychodów ze sprzedaży na kolejne okresy.

Spółka utrzymuje pewien stały krąg odbiorców związanych z firmą różnymi programami lojalnościowymi, nie umożliwia to jednak utrzymania sprzedaży na stałym, przeciętnym poziomie. Widoczne są dosyć znaczne wahania w poziomie przychodów ze sprzedaży w poszczególnych miesiącach.

Ze względu na dostępne dane do wyznaczenia prognozy przychodów ze sprzedaży zaproponowano użycie modeli szeregów czasowych. Celem budowanej prognozy było stworzenie podstaw do określenia planu finansowego oddziału.

Miesięczne przychody ze sprzedaży produktów w badanej filii przedstawiono w formie wykresu na rvs.1.



Rys. 1. Miesięczne przychody ze sprzedaży w latach: styczeń 1998 – kwiecień 2002  
Źródło: dane wewnętrzne przedsiębiorstwa.

Dostępny szereg czasowy liczy 56 miesięcznych obserwacji, z tego do budowy modelu przyjęto 52 obserwacje, natomiast cztery ostatnie pozostawiono w celu porównania z prognozami uzyskanymi w efekcie zastosowania modelu.

Ze wstępnej oceny wykresu oraz z charakteru zjawiska można wnioskować, iż w szeregu występuje trend oraz wahania. Na tym etapie analizy nie jest jasny charakter wahań - przypadkowe czy sezonowe.

Sporządzony wykres szeregu (rys. 1) sugeruje, iż jest to szereg niestacjonarny. Z reguły rozpatruje się dwa rodzaje niestacjonarności: niestacjonarność ze względu na średnią oraz niestacjonarność ze względu na wariancję.

W celu zweryfikowania założenia o niestacjonarności podzielono badany szereg na cztery grupy według kolejnych, równych przedziałów czasu. Testem t-Studenta oceniono istotność zróżnicowania przeciętnego poziomu przychodów w wydzielonych grupach. Stwierdzono istotne zróżnicowanie ( $p < 0,05$ ) przeciętnych przychodów między wszystkimi parami grup, oprócz pary 2-3. Do oceny istotności zróżnicowania wariancji przychodów między grupami zastosowano test jednorodności Levene'a. Nie stwierdzono istotnych różnic poziomu wariancji między grupami ( $p < 0,05$ ). Otrzymane wyniki przedstawiono w tab. 1.

Tabela 1. Analiza średniej i wariancji

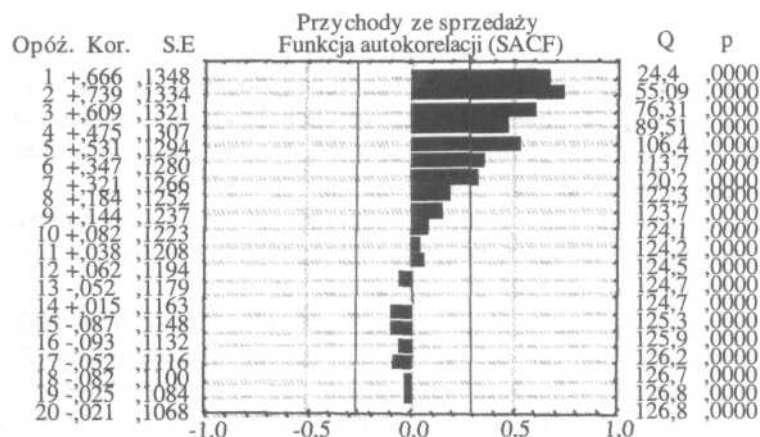
Grupy	Średnie		$p$	Wariancje		$p$ Levene'a
1:2	4837276,96	4041195,40	0,00	1,7E+11	1,1E+11	0,22
1:3	4837276,96	4097551,89	0,00	1,7E+11	1,6E+11	0,56
1:4	4837276,96	3670284,33	0,00	1,7E+11	6,2E+10	0,06
2:3	4041195,40	4097551,89	0,69	1,06E+11	1,6E+11	0,26
2:4	4041195,40	3670284,33	0,00	1,06E+11	6,2E+10	0,53
3:4	3670284,33	3670284,33	0,00	1,62E+11	6,2E+10	0,28

Źródło: obliczenia własne.

Wyniki powyższej analizy statystycznej sugerują konieczność różnicowania szeregu, nie istnieje natomiast potrzeba transformacji danych w celu stabilizacji wariancji.

Innym dogodnym narzędziem badania stacjonarności szeregu ze względu na średnią jest korelogram. Wyznaczone dla analizowanego szeregu wartości współczynników autokorelacji przedstawiono na rys. 2.

Przebieg funkcji autokorelacji sugeruje niestacjonarność szeregu. Dla przyjętego poziomu istotności  $\alpha = 0,05$  statystycznie istotnie różne od zera okazały się współczynniki autokorelacji dla opóźnień od 1 do 7 miesięcy. Potwierdza to wcześniejsze przypuszczenie o niestacjonarności szeregu czasowego miesięcznych przychodów ze sprzedaży.



s. 2. Współczynniki autokorelacji szeregu czasowego miesięcznych przychodów ze spr  
Źródło: obliczenia własne.

Za podstawę wyboru rzędu różnicowania można zaproponować porównanie wariancji dla szeregów o różnym stopniu różnicowania. Wybiera się rząd różnicowania, dla którego badany szereg ma najmniejszą wariancję. Wartości wariancji dla szeregów: pierwotnego ( $Y_t$ ), jedno- ( $DY_t$ ) i dwukrotnie zróżnicowanego ( $D^2Y_t$ ) przedstawiono w tabeli 2.

Tabela 2. Wariancje szeregu  $Y_t$ ,  $DY_t$ ,  $D^2Y_t$

Szereg	$Y_t$	$DY_t$	$D^2Y_t$
Wariancja	2,8E+11	1,5E+11	5,0E+11

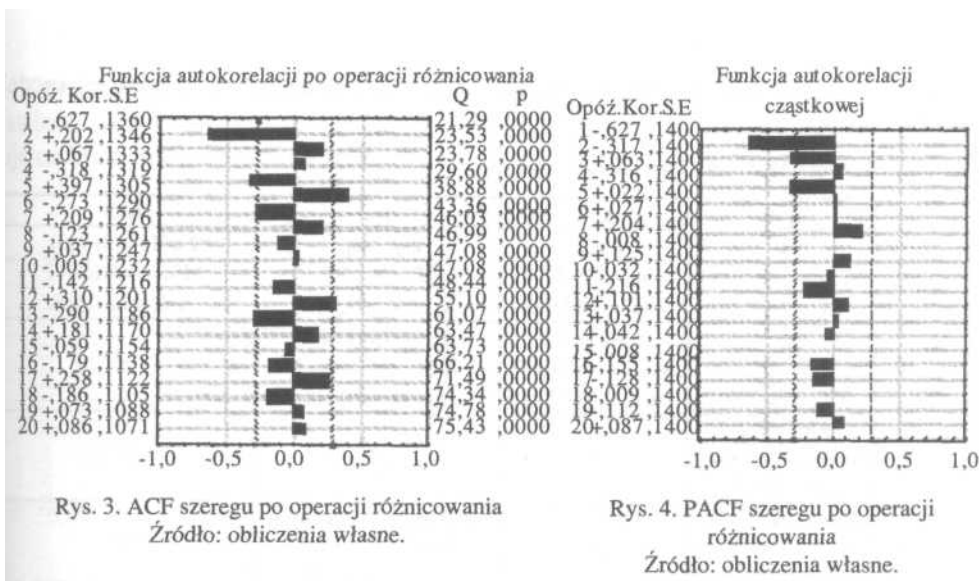
Źródło: obliczenia własne.

Najmniejszą wartość wariancji uzyskano dla szeregu jednokrotnie zróżnicowanego. Wobec tego w celu eliminacji niestacjonarności szereg poddano operacji różnicowania rzędu pierwszego. Wyznaczone dla szeregu zróżnicowanego wartości współczynników autokorelacji i autokorelacji cząstkowej przedstawiono na rys. 3-4.

Pierwsza wartość funkcji autokorelacji szeregu zróżnicowanego zmieniła znak w stosunku do wartości obliczonej dla szeregu pierwotnego i ma wartość ok. -0,5, co może sugerować przeróżnicowanie szeregu. Stan taki spowodować mogła równość średnich w grupach 2 i 3.

Przeróżnicowanie szeregu może zostać skompensowane poprzez uwzględnienie dodatkowego członu autoregresji w modelu. Analogicznie, niedoróżnicowanie szeregu może zostać skompensowane poprzez dodatkowy człon średniej ruchomej.

Wykresy funkcji autokorelacji (rys. 3-4) wskazują, iż szereg uzyskany w wyniku różnicowania jest szeregiem stacjonarnym ze względu na średnią.



Rys. 3. ACF szeregu po operacji różnicowania  
Źródło: obliczenia własne.

Rys. 4. PACF szeregu po operacji różnicowania  
Źródło: obliczenia własne.

Przebieg funkcji ACF wykazuje wykładnicze zanikanie wartości współczynników autokorelacji, co jest charakterystyczne dla modelu autoregresji. Nie do końca klarowny jest obraz funkcji PACF. Na przyjętym poziomie istotności  $\alpha = 0,05$  istotne są wartości funkcji PACF dla opóźnień równych 1, 2 i 4. Pojawienie się znaczącej autokorelacji cząstkowej dla czwartego opóźnienia utrudnia jednoznaczny wybór modelu. Ponieważ przekroczenie nie jest zbyt duże, przyjęto, że może być ono przypadkowe (błąd estymacji). Przy takim założeniu uzyskane obrazy funkcji ACF i PACF można uznać jako wskazujące model autoregresji rzędu 2 - AR (2).

Zwykle dany szereg czasowy można opisać różnymi modelami ARIMA. W praktyce ogranicza się często rząd modelu do 3. W celu przedstawienia modeli alternatywnych do AR (2) sprawdzono również inne kombinacje członów AR i MA. Jako kryterium wyboru najlepszego modelu przyjęto:

- istotność parametrów modelu (parametry istotne statystycznie zapisano w tabeli kursywą),
- najmniejszą wartość błędu średniokwadratowego (MSE),
- kryterium informacyjne (AIC).

Ze względu na obecność trendu uwzględniono w modelu czynnik stały. Testowane modele zestawiono w tab. 3.

Modele niestabilne, dla których oceny parametrów są bardzo bliskie lub większe od 1, oznaczono w tabeli znakiem „X”.

Na podstawie przeprowadzonej analizy wybrano model ARIMA (2,1,0). Ponieważ w momencie rozważania konieczności różnicowania szeregu powstała wątpliwość co do rzędu różnicowania, sprawdzono również diagnostyczny szereg niezróżnicowany. Przeprowadzono analogiczną analizę jak poprzednio, wybierając spośród klasy modeli ARMA model średniej ruchomej 2 rzędu. Model ten charak-

teryzuje się gorszymi wskaźnikami jakości niż zaproponowany wcześniej model ARIMA (2,1,0).

Tabela 3. Wartość MSE i AIC dla ARIMA (p,1,q)

	q=0	q=1	q=2	q=3
p=0	c MSE = 1,50E+11 AIC = 659,389	c q(1) MSE = 9208E+7 AIC = 649,925	c q(1) q2 MSE = 8758E+7 AIC = 649,925	c q(1) q(2) (q3) MSE = 8850E+7 AIC = 651,685
p=1	c p(1) MSE = 9316E+7 AIC = 649,789	c p(1) q(1) MSE = 8686E+7 AIC = 651,726	c p(1) q(1) q(2) MSE = 9316E+7 AIC = 649,789	×
p=2	c p(1) p(2) MSE = 8618E+7 AIC = 649,561	×	×	×
p=3	C p(1) p(2) p(3) MSE = 8747E+7 AIC = 651,420	×	c p(1)p(2)p(3)q(1)q(2) MSE = 8357E+7 AIC = 653,409	×

Źródło: obliczenia własne.

Wyniki obliczeń wykonanych dla modelu MA 2 przedstawiono w tab. 4.

Tabela 4. Wartość MSE i AIC dla ARMA

	q=2
p=0	c q(1) q(2) MSE = 1290E+8 AIC = 658,65

Źródło: obliczenia własne.

Ostatecznie po analizie wyników do budowy prognozy przychodów ze sprzedaży przyjęty został model ARIMA(2,1,0).

W postaci rozwiniętej model ten można zapisać jako:

$$(1 - \phi_1 B - \phi_2 B^2) (1 - B) y_t = c + e_t \quad (2)$$

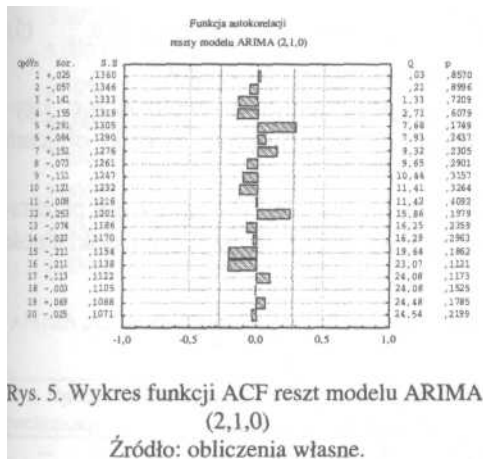
Estymacji parametrów modelu dokonano za pomocą przybliżonej metody największej wiarygodności według McLeoda i Salesa, uzyskując model:

Rezygnując z zapisu operatorowego, uzyskuje się model zapisany w postaci jawnej:

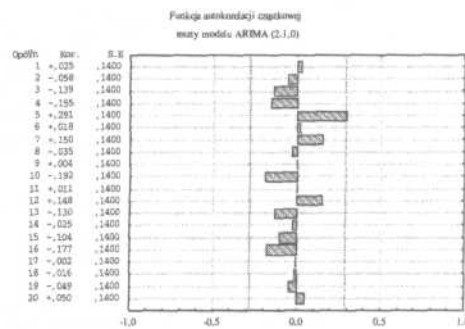
$$\hat{y}_t = -29296 + (1 - 0,831) y_{t-1} + (0,831 - 0,319) y_{t-2} + 0,319 y_{t-3} + e_t \quad (4)$$

Stałą  $c$  w modelu można interpretować jako współczynnik kierunkowy trendu szeregu nieodróżnicowanego. Oszacowane parametry modelu spełniają warunki zapewniające stabilność modelu.

Estymowany model poddano następnie sprawdzeniu diagnostycznemu. Przedstawione na rys. 5-6 wykresy przebiegu funkcji ACF i PACF reszt modelu wskazują na brak autokorelacji reszt.



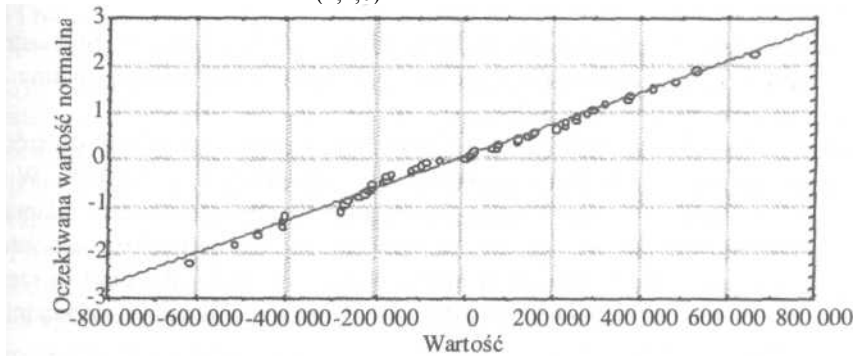
Rys. 5. Wykres funkcji ACF reszt modelu ARIMA (2,1,0)  
Źródło: obliczenia własne.



Rys. 6. Wykres funkcji PACF reszt modelu ARIMA (2,1,0)  
Źródło: obliczenia własne.

Rozkład reszt nie odbiega od rozkładu normalnego (rys. 7), co pozwala przyjąć, że reszty są procesem białego szumu i nie zawierają składowej systematycznej.

Normalny wykres prawdopodobieństwa reszty modelu ARIMA (2,1,0)



Rys. 7. Normalny wykres prawdopodobieństwa reszt modelu ARIMA (2,1,0)  
Źródło: obliczenia własne.

Analizę wizualną uzupełniono analizą ilościową. Dla funkcji autokorelacji reszt modelu wykonano obliczenia według testu zgodności Boxa Pierce'a.

Wynik testu wskazuje, iż nie ma podstaw do odrzucenia hipotezy o losowości reszt modelu

$$Q = 52 \sum_{k=1}^{\infty} r_k^2 = 19,17; \chi^2 = 27,59; Q < \chi^2.$$



Wobec pozytywnych wyników sprawdzenia diagnostycznego wyznaczony model uznano za przydatny do wyznaczenia prognoz przychodów ze sprzedaży na kolejne miesiące. Po przeindeksowaniu uzyskuje się postać modelu dogodną do obliczenia prognoz:

$$y_{t+1}^* = -29296 + (1-0,831)y_t + (0,831-0,319)y_{t-1} + 0,319y_{t-2} + e_{t+1} \quad (5)$$

gdzie:  $y_{t+1}^*$  - prognoza wartości zmiennej prognozowanej na okres  $y_{t-1}$

Korzystając z modelu (5) wyznaczono prognozy jedno- i dwukrokowe. Uzyskane wyniki porównano z rzeczywistą wartością przychodów. Wyniki obliczeń zestawiono w tab. 5.

W przypadku prognozy jednokrokowej procentowy błąd prognozy nie przekracza 7%, w przypadku dwukrokowej 10%. Można uznać, iż uzyskana dokładność jest zadowalająca.

Tabela 5. Jedno- i dwukrokowa prognoza przychodów ze sprzedaży wyznaczona modelem ARIMA (2,1,0)

Nr kolejnego miesiąca	Dane obserwowane	Prognoza przychodów ze sprzedaży		Błąd procentowy	Prognoza przychodów ze sprzedaży		Błąd procentowy
		$y_{s2+1}^*$	<b>3701162</b>		—	—	
53	3670583	$y_{s2+1}^*$	<b>3701162</b>	-0,83%	$y_{s2+2}^*$	<b>3701162</b>	-5,7%
54	3501701	$y_{s3+1}^*$	<b>3726114</b>	-6,41%	$y_{s3+2}^*$	<b>3731262</b>	-1,6%
55	3671797	$y_{s4+1}^*$	<b>3575170</b>	2,63%	$y_{s4+2}^*$	<b>3629489</b>	-9,9%
56	3296919	$y_{s5+1}^*$	<b>3521196</b>	-6,80%	$y_{s5+2}^*$	<b>3641524</b>	
57	—	$y_{s6+1}^*$	<b>3491434</b>				

Źródło: obliczenia własne.

Z powodu małej liczby danych dostępnych do budowy modelu wyznaczona prognoza powinna być monitorowana, w razie niskiej trafności powinny być wprowadzane korekty użytego modelu.

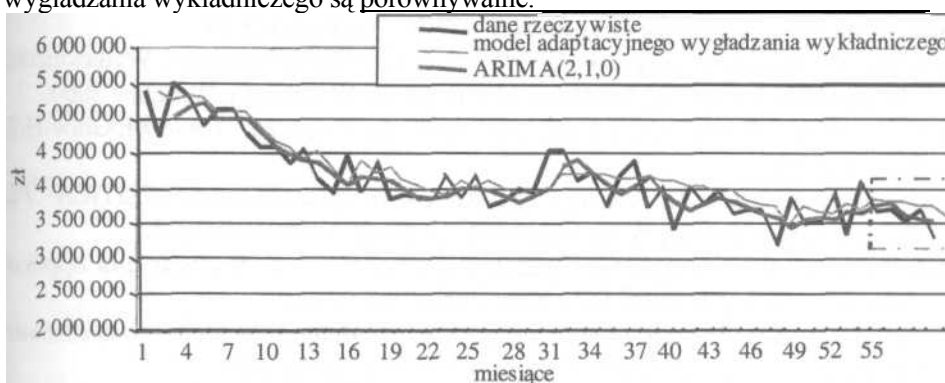
Wielu autorów twierdzi, że modele ARIMA dają najlepsze rezultaty spośród innych modeli statystycznych. Autorzy referatu nie podzielają tego poglądu. W celu ilustracji zagadnienia wykonano również prognozę za pomocą modelu adaptacyjnego wykładniczego. Uzyskane rezultaty dla prognozy jednokrokowej przedstawiono w tab. 6. Na rys. 8 przedstawiono wykresy dla danych rzeczywistych oraz uzyskanych z modeli ARIMA (2,1,0) oraz wykładniczego-

Tabela 6. Prognoza przychodów ze sprzedaży wyznaczona metodą wykładniczego

Nr kolejnego miesiąca	Dane obserwowane	Prognoza przychodów ze sprzedaży		Błąd procentowy
53	3670583	$y_{s2+1}^*$	3775188,7	-2,8%
54	3501701	$y_{s3+1}^*$	3756665,2	-7,3%
55	3671797	$y_{s4+1}^*$	3701485,1	-0,8%
56	3296919	$y_{s5+1}^*$	3692357,6	-12,0%
57	—	$y_{s6+1}^*$	3566667,1	

Źródło: obliczenia własne.

Dokładność prognoz uzyskanych z modelu ARIMA i modelu adaptacyjnego wykładniczego są porównywalne.



Rys. 8. Prognoza przychodów ze sprzedaży  
Źródło: obliczenia własne.

#### 4. Wnioski

Wykorzystując modele ARIMA do prognozowania szeregów czasowych, można spotkać się z wieloma problemami m.in. dotyczącymi określenia rzędu różnicowania i rodzaju modelu. Opracowanie modeli jest dosyć pracochłonne i wymaga specjalistycznej wiedzy. Zastosowanie modeli ARIMA nie gwarantuje w każdym przypadku lepszych wyników w porównaniu z wynikami otrzymanymi innymi prostszymi metodami. Sprawia to, iż w prognozowaniu gospodarczym, zwłaszcza w skali przedsiębiorstwa stosowane są one dosyć rzadko. Mają one jednak tę zaletę, iż wskazują na wewnętrzną strukturę szeregu i objaśniają mechanizm jego generowania.

Proponowane podejście ilościowe wzbogaca informację decyzyjną i poszerza metodologię prognozowania stosowaną obecnie w przedsiębiorstwie. Dotychczas firma szacowała przyszłą wartość przychodów ze sprzedaży, opierając się na opinii bezpośrednich sprzedawców (metoda ekspertowa). Formulowane opinie były jednak niejednokrotnie oparte na fałszywych przesłankach prognostycznych, co wpływało negatywnie na trafność tak wyznaczonych prognoz.

Wydaje się, iż najbardziej efektywnym podejściem byłoby połączenie w procesie prognostycznym metod jakościowych oraz ilościowych.

Narzędziem informatycznym wykorzystanym w procesie opracowania modelu i wyznaczania prognoz był moduł *Szeregi czasowe i prognozowanie* programu STATISTICA PL wersji 6.0. *Artykuł powstał w ramach pracy badawczej nr W/WZ/3/02*

## Literatura

- Cieślak M., *Prognozowanie gospodarcze*, PWN, Warszawa 2001.
- Dittmann P., *Metody prognozowania sprzedaży w przedsiębiorstwie*, Wydawnictwo Akademii Ekonomicznej im. Oskara Langego we Wrocławiu, Wrocław 2000.
- Delurgio S.A., *Forecasting Principles and Applications*, Irwin/McGraw-Hill, Boston 1998.
- Luszniewicz A., Słaby T., *Statystyka z pakietem komputerowym STATISTICA™PL Teoria i zastosowania*, Wydawnictwo C.H. Beck, Warszawa 2001.
- Makridakis S., Wheelwrigth S., Hyndman R., *Forecasting. Methods and Applications*, John Wiley & Sons, Inc., New York 1998.
- Nowak E. (red.), *Prognozowanie gospodarcze. Metody, modele, zastosowanie, przykłady*, Agencja Wydawnicza PLACET, Warszawa 1998.
- Rutkowski K. (red.), *Logistyka dystrybucji*, Difin, Warszawa 2001.

## ARIMA MODELS IN FORECASTING SALES GROSS INCOME FOR CASH & CARRY TRADE ENTERPRISE

### Summary

The paper presents construction methodology of ARIMA models and their application in one-dimensional time series forecasting. The Box and Jenkins approach, being one of the widely used, has been employed. Consecutive phases of constructing the model have been described and discussed on the basis of a *cash & carry* type of trade enterprise. The necessary data transformation has been carried out, potentially useful models have been initially identified, the parameters of these models have been estimated and a best possible model has been chosen according to certain criteria. The process of selecting the model has been discussed and the model itself has been tested diagnostically. Model selected by this kind of methodology formed the basis for indication of the sales income forecasting.

The quantitative approach suggested in the paper broadens methodology of forecasting that has been hitherto implemented in the enterprise and at the same time enriches the executive data of management of company. A *Time Series and Forecasting module* of STATISTICA PL 6.0 programme was the software used in the process of creating the model and indication of the forecasting.