

Zbigniew Mongiła

MODELE BOXA-JENKINSA GŁÓWNYCH ZMIENNYCH MAKROEKONOMICZNYCH POLSKI

BOX-JENKINS MODELS AS A MAIN POLISH MACROECONOMIC VARIABLES

Katedra Zastosowań Matematyki w Ekonomii, Zachodniopomorski Uniwersytet Technologiczny w Szczecinie
ul. Klemensa Janickiego 31, 71-270 Szczecin

Abstract. The study examined a method to identify the Box-Jenkins model on the real polish macroeconomic variables. Models were constructed for these variables and estimated their parameters. In this study also proposed a different way of identification of Box-Jenkins models. Indicated which information will be needed to construct forecasts for the variables tested on the results of the models.

Słowa kluczowe: inflacja, bezrobocie, model Boxa-Jenkinsa, PKB.

Key words: Box-Jenkins model, GDP–Gross Domestic Product, inflation, unemployment.

WSTĘP

Kształtowanie się zmiennych ekonomicznych w czasie może być opisane za pomocą modeli, w których szereg czasowy może być traktowany jako realizacja procesu stochastycznego. W metodzie zaproponowanej przez Boxa i Jenkinsa (1983) szeregi traktowane są jako realizacje procesów stochastycznych. Zbudowanie i oszacowanie modelu opisującego zmiany w czasie ściśle się wiąże z możliwością przewidywania jej wartości w przyszłości (Welfe 1998, Zeliaś 2004).

Szybki rozwój komputerów spowodował, że występująca wcześniej bariera, związana z dużą pracochłonnością obliczeń, przestała istnieć. Niemniej jednak, jak podkreśla wielu użytkowników tej metody (Chraślowska i Nazarko 2003, Dudek 2007), jej prawidłowe stosowanie w badaniach empirycznych wymaga znacznego doświadczenia.

Celem pracy było oszacowanie modeli (i ich parametrów) opisujących trendy i wahania sezonowe czterech zmiennych makroekonomicznych Polski.

METODA

Miesięczne lub kwartalne dane, wykorzystane w badaniu, pochodzą z Biuletynów Statystycznych GUS-u z okresu od stycznia 1998 r. do maja 2009 r. Dane kwartalne dotyczyły przyrostu PKB [%], a dane miesięczne – stopy bezrobocia [%], stopy inflacji rocznej [%] oraz podaży pieniądza M1 [mld zł].

Obliczenia związane ze specyfikacją oraz z estymacją modeli wykonano za pomocą odpowiednich modułów pakietu Statistica PL. Posłużono się przede wszystkim w ramach modułu „szeregów czasowych” procedurą: analiza Fouriera (widmowa). Jej zastosowanie pozwoliło ustalić liczbę opóźnień, którą należy uwzględnić w budowanym modelu. Następnie wyliczono autokorelacje i autokorelacje cząstkowe od 1 do 15 (opcjonalne ustawienie

w pakiecie jest wystarczające, żeby określić kształt rozkładu tych współczynników) lub 20 opóźnień. Pozwoliło to na dokonanie wstępnej decyzji o klasie modelu, tzn. o zaliczeniu go do modeli typu: AR, ARI lub SAR, SARI (wiedza na temat wielkości aktualnej wartości badanej cechy zawarta jest we wcześniejszych wartościach tej cechy) czy MA, IMA lub SMA, SIMA (wiedza na temat wielkości aktualnej wartości badanej cechy zawarta jest we wcześniejszych wartościach składnika losowego tej cechy), czy ARMA, ARIMA lub SARMA, SARIMA (wiedza na temat wielkości aktualnej wartości badanej cechy zawarta jest we wcześniejszych wartościach tej cechy i wartościach składnika losowego). Literka I przy typie modelu oznacza, że zastosowano operacje różnicowania w celu uzyskania stacjonarności danych (doprowadzenia do sytuacji braku trendu wzrostowego lub malejącego w analizowanych danych), a litera S oznacza, że w modelu uwzględniono wahania okresowe. Decyzję o uznaniu modelu za dobrze dopasowany do badanych danych oparto na następujących przesłankach:

- 1) wybrany model powinien mieć wszystkie parametry statystycznie istotne,
- 2) wszystkie współczynniki autokorelacji i autokorelacji cząstkowej reszt co najmniej do 15 opóźnień powinny być nieistotne statystycznie (test Ljungu Boxa),
- 3) aby nie można było odrzucić hipotezy, że kształt rozkładu reszt jest normalny (test zgodności λ -Kolmogorowa).

We wszystkich testach istotności przyjmowano poziom istotności równy 0,05.


WYNIKI I DYSKUSJA

Za jeden z najważniejszych mierników syntetycznych charakteryzujących stan gospodarki krajowej uważa się wskaźnik PKB (Wyźnikiewicz i in. 2009). Miernik ten, wyrażony w stosunku do wartości sprzed roku, informuje, w jakiej fazie znajduje się rozwój gospodarki krajowej. W latach 1998–2009 wykazywał on na ogół tendencję wzrostową (rys. 1). Można jednak w jego kształtowaniu się wyodrębnić 4 okresy wyhamowywania i 3 okresy przyspieszenia rozwoju gospodarki. Na 137 obserwowanych miesiący zmiana trendu następowała 7 razy, czyli przeciętnie co 20 miesięcy. Stosując analizę Fouriera (rys. 1) dla danych określających przyrosty PKB, uzyskano periodogram (dla lepszej wyrazistości zależność oś Y została zlogarytmowana). Te punkty osi X, dla których periodogram przyjmuje największe wartości, można traktować jako przybliżony okres wahań badanej zmiennej (Box i Jenkins 1983). Z periodogramu można wnioskować, że wielkości okresów dla przyrostów PKB należy poszukiwać w pobliżu liczb – 3, 8, 15 kwartałów.


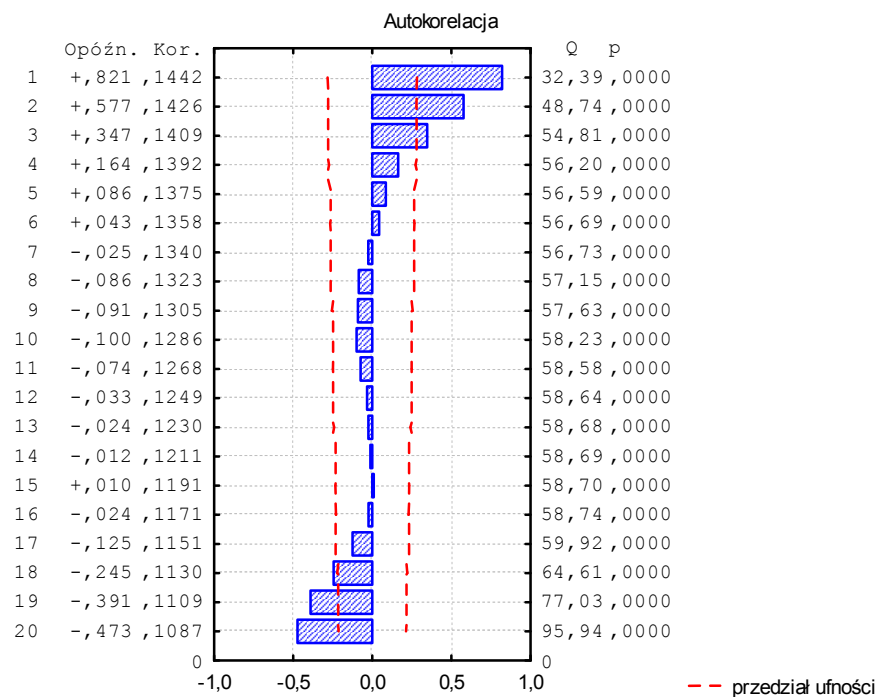
Z kształtu zanikania słupków na rys. 2 przedstawiającego autokorelację i autokorelację cząstkową dla tej zmiennej, można wnioskować, że należy brać pod uwagę model AR rzędu 1. Jednak autokorelacje nie zanikają wykładniczo, lecz mają kształt funkcji okresowej, więc może też należy uwzględnić model MA, czyli w sumie model ARMA.

Model ARMA(1 0 1) okazał się prawie dobry, gdyż miał wszystkie parametry statystycznie istotne i spełniające warunek odwracalności; reszty miały rozkład normalny, niestety występowała w nich autokorelacja cząstkowa istotnie różna od zera na opóźnieniu 8. Uwzględnienie okresu w modelu ARMA(1 0 1) i SAR(2) z okresem 4 lub ARMA(1 0 1) i SMA(1) z okresem 4 umożliwiało lepsze szacowanie modelu (były to okresy najlepsze wśród

wszystkich rozpatrywanych), jednak nie pozwoliły pozbyć się powyższej niedogodności. Występowanie istotnej autokorelacji przesunęło się na 20 opóźnienie. Stąd w dalszych analizach tej cechy uwzględniano różnicowanie. Modelem, który spełniał wszystkie powyższe kryteria, był model ARIMA(0 1 0) i SAR(2) z okresem 4 wyrażonym następująco (tab. 1): $\Delta y_t = -0,689\Delta y_{t-4} - 0,476\Delta y_{t-8} + \sigma$.



Rys. 1. Kwartalne wartości zmiany PKB w Polsce, wyrażone w procentach oraz wykres analizy Fouriera (widmowej) i zlogarytmowane wartości periodogramu


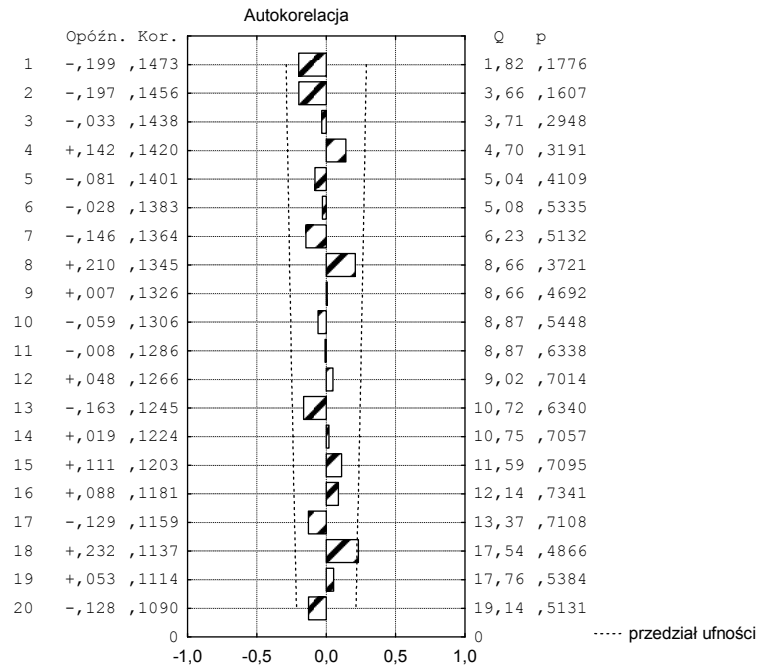


Rys. 2. Wykres autokorelacji i autokorelacji cząstkowej dla PKB w Polsce

Tabela 1. Parametry modelu opisującego zmienność PKB

| | Parametr | Asymptotyczny błąd standardowy | Asymptotyczny $t(41)$ | p | Dolna granica 95-procentowy poziom ufności | Górna granica 95-procentowy poziom ufności |
|---------|----------|--------------------------------|-----------------------|-------|--|--|
| $Ps(1)$ | -0,688 | 0,158 | -4,341 | 0,000 | -1,008 | -0,368 |
| $Ps(2)$ | -0,476 | 0,153 | -3,117 | 0,003 | -0,784 | -0,168 |


Model:(0,1,0)(2,0,0), opóźnienia dla sezonowości – 4, resztowy $MS = 0,886$.



Rys. 3. Wykres autokorelacji i autokorelacji cząstkowej dla reszt z modelu ARIMA(0 1 0) i SAR(2) z okresem 4 dotyczącym przyrostów PKB w Polsce

Wartość: SW-W = 0,9881, $p = 0,9297$, $D = 0,0777$, $p < n.i.$, p -Lillieforsa < 1


Wartość = 43:0,5normal(x: -0,0105; 0,8977)



Rys. 4. Kształt rozkładu reszt z modelu ARIMA(0 1 0) i SAR(2) z okresem 4 dotyczącym przyrostów PKB w Polsce

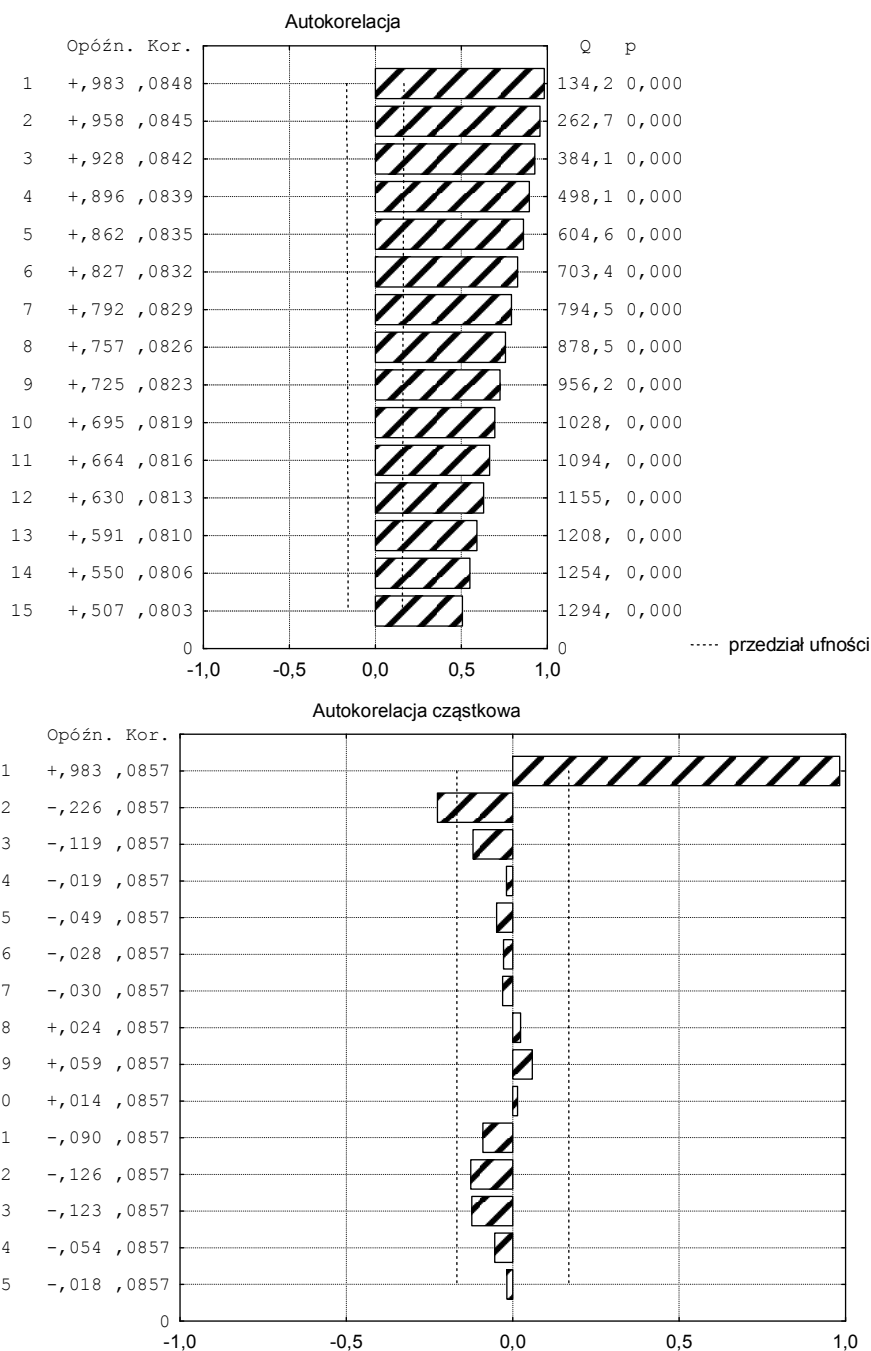
Z rysunków 3 i 4 wynika, że reszty nie wykazują statystycznie istotnej autokorelacji i autokorelacji cząstkowej oraz że brakuje podstaw do odrzucenia hipotezy o normalności rozkładu tych reszt.

Stopa bezrobocia (rys. 5) od września 1998 do stycznia 2004 roku miała trend rosnący, a od stycznia 2004 do października 2008 – malejący. Można zauważyć, że stopa bezrobocia w końcowych i początkowych miesiącach roku zawsze się zwiększa i pod koniec I kwartału i na początku II kwartału wykazuje tendencję spadkową. Analiza Fouriera stopy bezrobocia w Polsce wskazuje, że wartości okresów, które należy wziąć pod uwagę, znajdują się przy liczbach 6, 12, 20 i 28.



Rys. 5. Miesięczne zmiany stopy bezrobocia w Polsce oraz wykres analizy Fouriera (widmowej) i zlogarytmowane wartości periodogramu

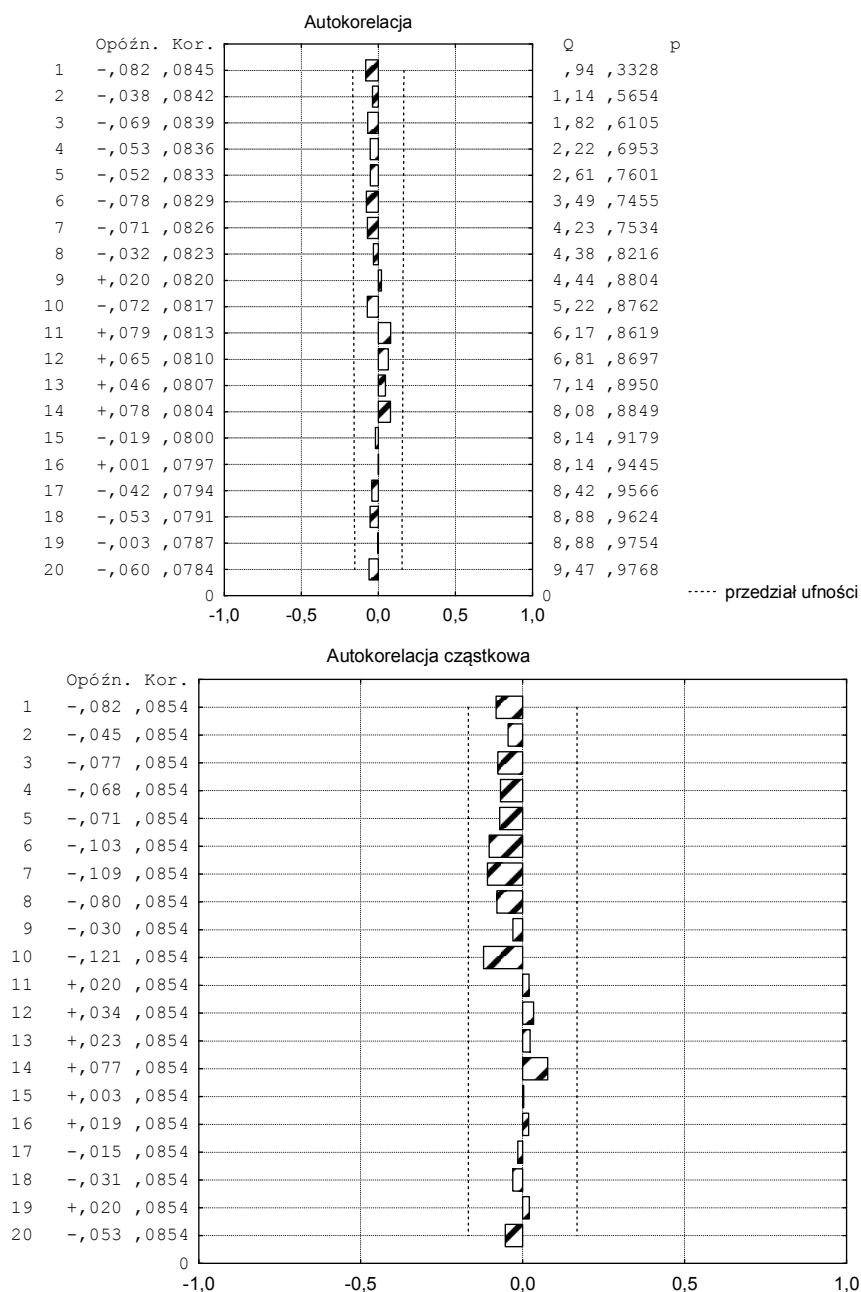
Z kształtu zanikania słupków na rys. 6, przedstawiającego autokorelację i autokorelację cząstkową dla tej zmiennej, można wnioskować, że należy zacząć poszukiwania modelu od AR rzędu 2. Model ten nie był dobry, mimo że wszystkie parametry były statystycznie istotne (wartość pierwszego parametru była większa od 1 – więc nie spełniał warunku odwracalności); dla reszt autokorelacja była statystycznie istotna już od 11 opóźnienia, a w autokorelacji cząstkowej istotność odnotowano już na 3 opóźnieniu.



Rys. 6. Wykres autokorelacji i autokorelacji cząstkowej dla stopy bezrobocia w Polsce

Modelem, który spełniał wszystkie założenia (rys. 7, 8), był bardzo rozbudowany model (tab. 2) ARIMA(4 2 0) i SAR(6) z okresem 12, wyrażony $\Delta^2 y_t = -0,6583\Delta^2 y_{t-1} - 0,4587\Delta^2 y_{t-2} - 0,318\Delta^2 y_{t-3} - 0,1974\Delta^2 y_{t-4} + 0,4052\Delta^2 y_{t-12} + 0,2244\Delta^2 y_{t-24} + 0,1774\Delta^2 y_{t-36} + 0,1824\Delta^2 y_{t-48}$

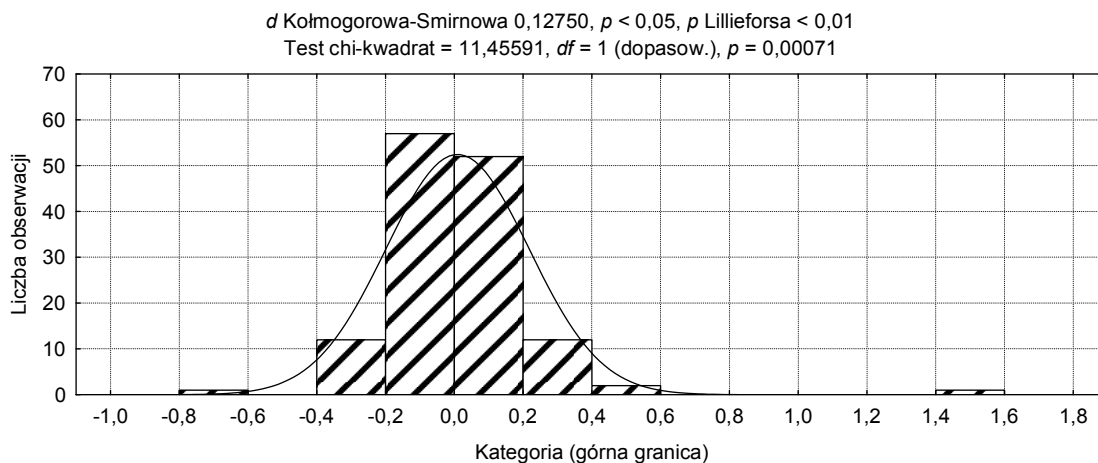
+ $0,358\Delta^2 y_{t-60} - 0,7183\Delta^2 y_{t-72} + \sigma$. Można było znaleźć prostszy model opisujący stopę bezrobocia w Polsce, rezygnując z założenia o normalności kształtu reszt. Na przykład w modelu ARMA(2 0 1) i SAR(2) z opóźnieniem 12 (błąd $MS = 0,07889$) hipotezy o normalności rozkładu nie można odrzucić dopiero wtedy, gdy wykluczy się jedną odstającą wartość reszt. Wartość tej reszty wynika z dużego wzrostu bezrobocia w styczniu 2004 roku.



Rys. 7. Wykres autokorelacji i autokorelacji cząstkowej dla reszt z modelu ARIMA(4 2 0) i SAR(6) z okresem 12 dotyczący stopy bezrobocia w Polsce

Kolejną zmienną poddaną analizie był stopień inflacji w Polsce, wyliczany miesięcznie w stosunku rocznym (rys. 9). W badanym okresie inflacja w Polsce miała trzy dłuższe okresy zmniejszania się i zwiększania się. W przebiegu stopnia inflacji można wyróżnić trend spadkowy do stycznia 2006 roku, a następnie trend wzrostowy. Inflacja od września 2001

roku nie przekraczała wartości 5%. Analiza Fouriera stopnia inflacji w Polsce wskazuje, że wartości okresów, które należy wziąć pod uwagę, znajdują się przy liczbach 5, 7, 8, 9, 10, 15, 17, 20, 23 i 28, 34, 46.



Rys. 8. Kształt rozkładu reszt z modelu ARIMA(4 2 0) i SAR(6) z okresem 12 dotyczącym stopy bezrobocia w Polsce

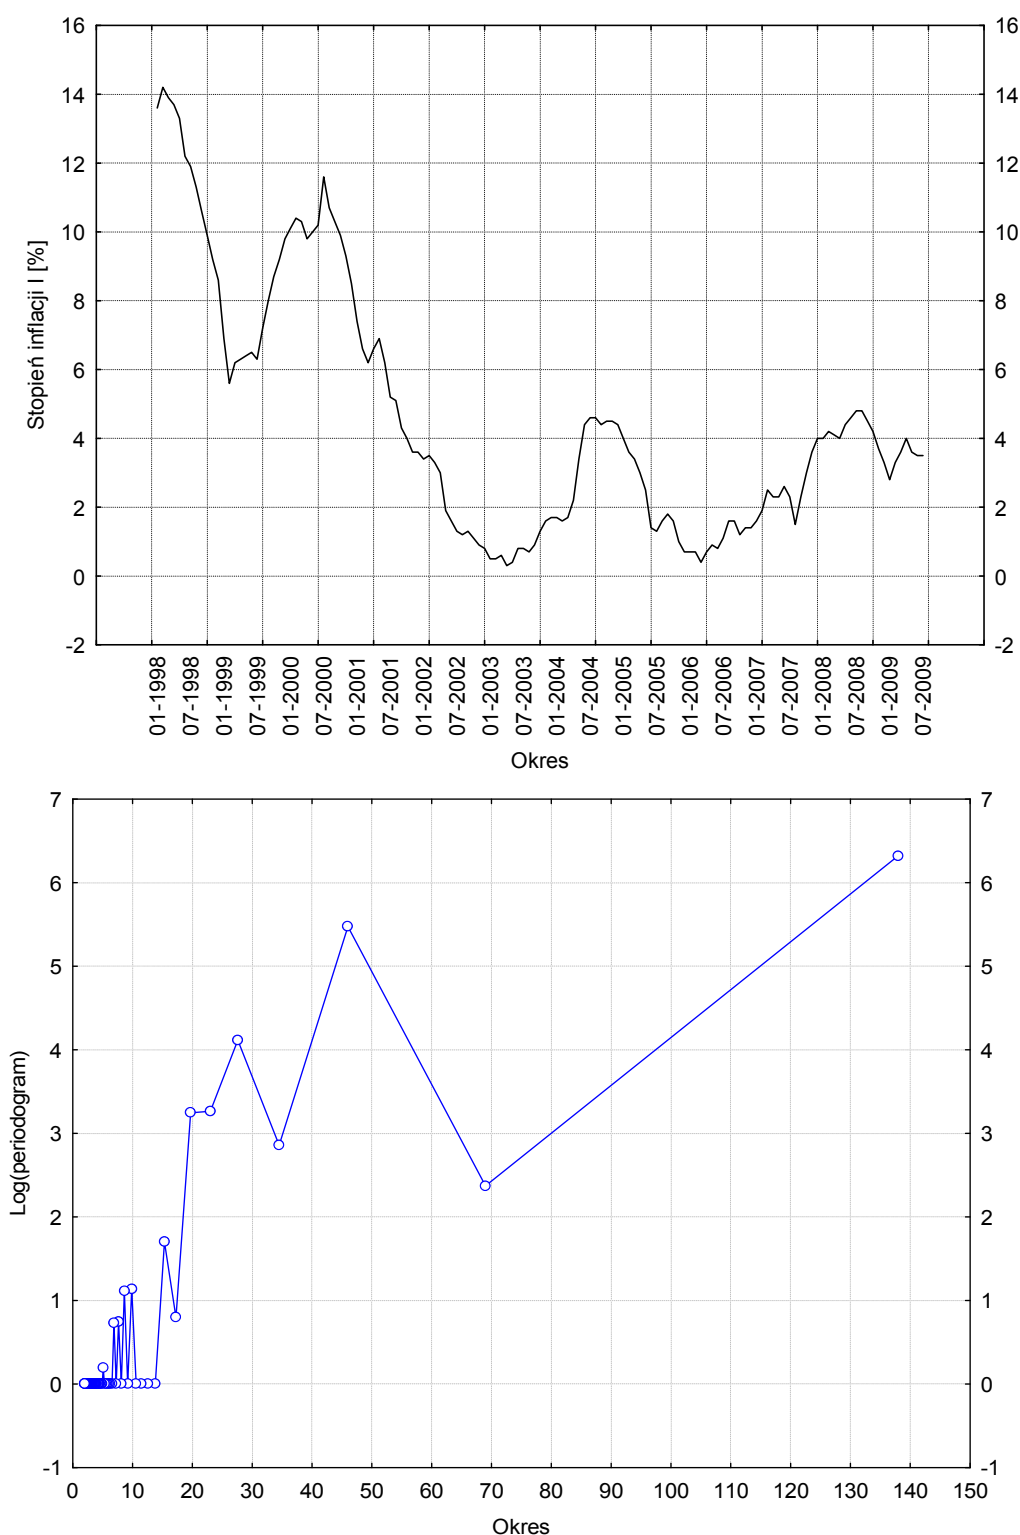
Tabela 2. Parametry modelu opisującego zmienność stopy bezrobocia w Polsce

| | Parametr | Asymptotyczny błąd standardowy | Asymptotyczny $t(127)$ | p | Dolna granica 95-procentowy poziom ufności | Górna granica 95-procentowy poziom ufności |
|---------|-----------|--------------------------------|------------------------|----------|--|--|
| $p(1)$ | -0,658320 | 0,101948 | -6,45741 | 0,000000 | -0,860057 | -0,456583 |
| $p(2)$ | -0,458700 | 0,116388 | -3,94114 | 0,000133 | -0,689010 | -0,228390 |
| $p(3)$ | -0,318045 | 0,109740 | -2,89817 | 0,004423 | -0,535200 | -0,100889 |
| $p(4)$ | -0,197604 | 0,090330 | -2,18757 | 0,030531 | -0,376352 | -0,018857 |
| $Ps(1)$ | 0,405250 | 0,061035 | 6,63963 | 0,000000 | 0,284473 | 0,526027 |
| $Ps(2)$ | 0,224404 | 0,063366 | 3,54137 | 0,000557 | 0,099014 | 0,349795 |
| $Ps(3)$ | 0,177361 | 0,078519 | 2,25884 | 0,025599 | 0,021987 | 0,332736 |
| $Ps(4)$ | 0,182411 | 0,060935 | 2,99355 | 0,003315 | 0,061832 | 0,302990 |
| $Ps(5)$ | 0,357992 | 0,059407 | 6,02611 | 0,000000 | 0,240437 | 0,475548 |
| $Ps(6)$ | -0,718267 | 0,096268 | -7,46110 | 0,000000 | -0,908765 | -0,527770 |

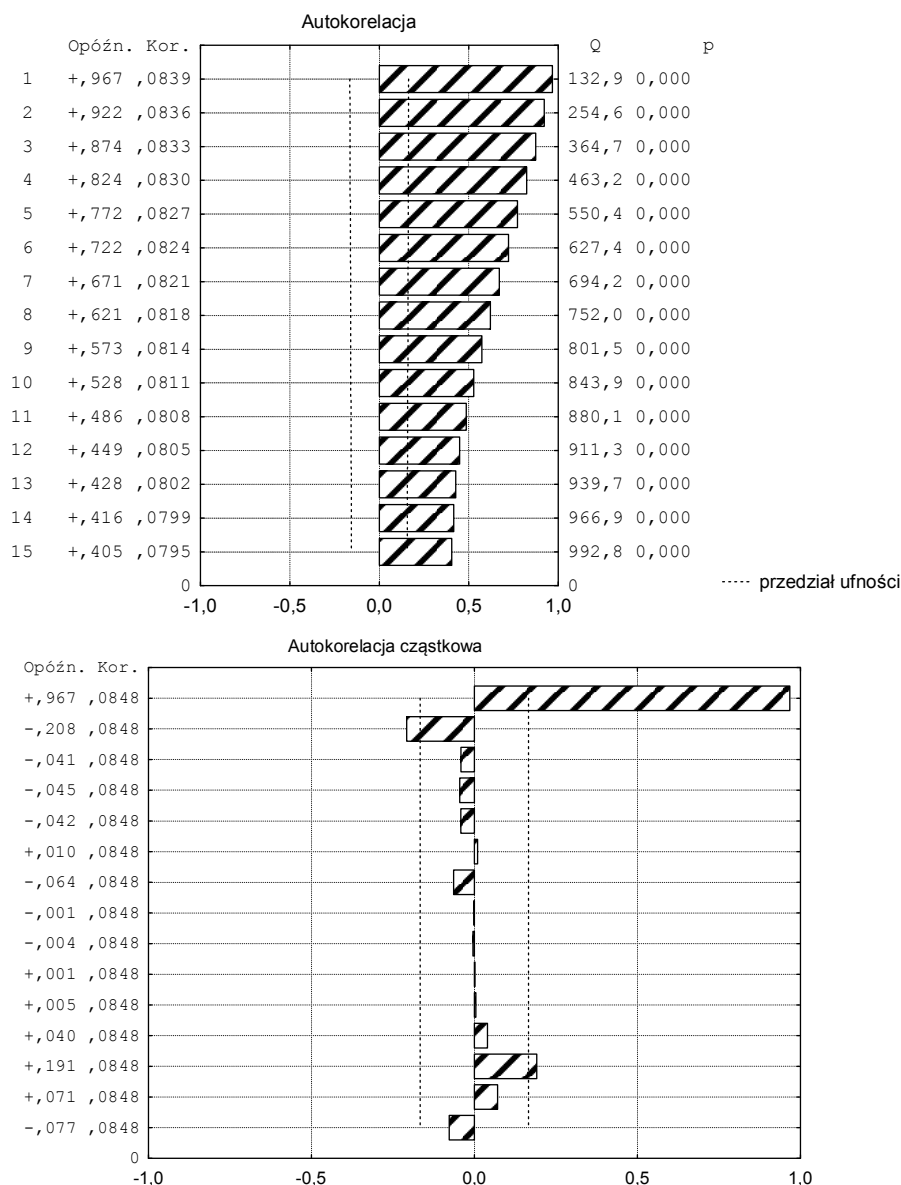
2*D(1), model: (4,2,0) (6,0,0), opóźnienia dla sezonowości: 12, resztowy MS = 0,07306.

Z kształtu zanikania słupków na rys. 10, przedstawiającym autokorelację i autokorelację cząstkową dla stopnia inflacji, można wnioskować, że należy zacząć poszukiwania modelu (tak jak w poprzednim przypadku) od AR rzędu 2. Model ten z uwzględnieniem stałej był prawie dobry, bo wszystkie parametry były statystycznie istotne. Niestety, wartość pierwszego parametru była większa od 1 (a więc nie spełniał on warunku odwracalności); dla reszt autokorelacja była statystycznie istotna już od 12 opóźnienia, a w autokorelacji cząstkowej istotność wystąpiła także na 12 opóźnieniu. Dla kształtu rozkładu reszt prawie nie można było odrzucić hipotezy o jego normalności. Niewielkie poprawienie tego modelu poprzez dorzuce-

nie SMA(1) z okresem 12 pozbawiło istotności autokorelację i autokorelację cząstkową; uzyskano brak podstaw do odrzucenia hipotezy o normalności kształtu reszt ($MS = 0,1709$).



Rys. 9. Miesięczne zmiany stopnia inflacji w Polsce, wyrażone w procentach, oraz wykres analizy Fouriera (widmowej) i zlogarytmowane wartości periodogramu



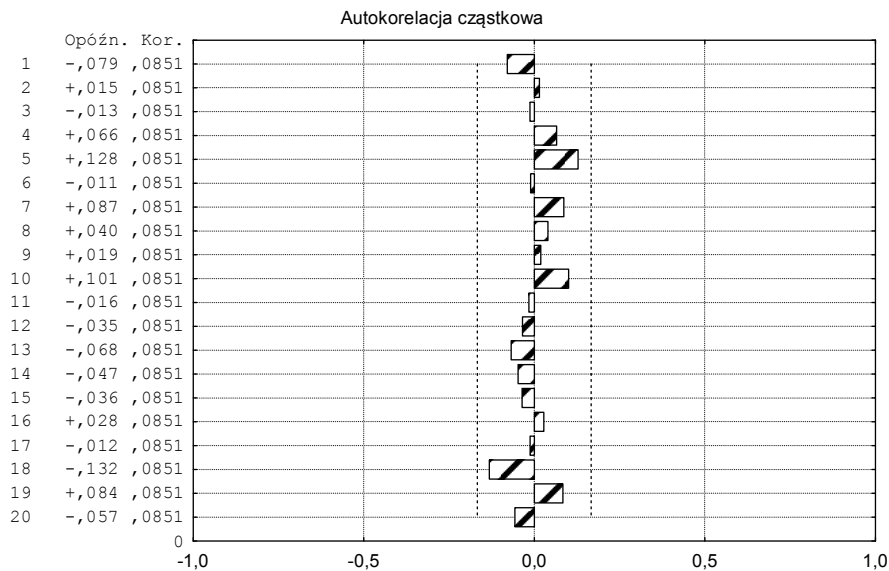

Rys. 10. Wykres autokorelacji i autokorelacji cząstkowej dla stopnia inflacji w Polsce

Tabela 3. Parametry modelu opisującego zmienność stopnia inflacji w Polsce

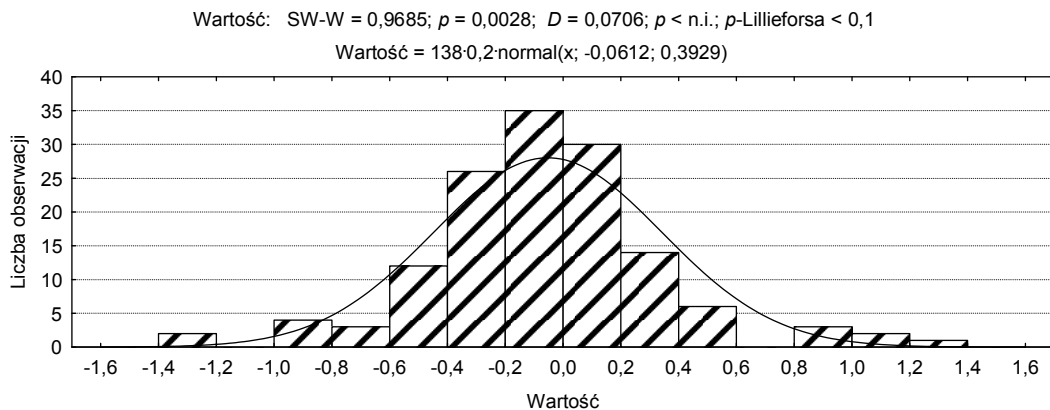
| | Parametr | Asymptotyczny błąd standardowy | Asymptotyczny t(127) | p | Dolna granica 95-procentowy poziom ufności | Górna granica 95-procentowy poziom ufności |
|--------|----------|--------------------------------|----------------------|----------|--|--|
| $p(1)$ | 0,493372 | 0,074448 | 6,627019 | 0,000000 | 0,346145 | 0,640598 |
| Qs(1) | 0,445455 | 0,081578 | 5,460504 | 0,000000 | 0,284130 | 0,606779 |

D(1), model: (1,1,0) (0,0,1), opóźnienia dla sezonowości: 12, resztowy MS = 0,16272.

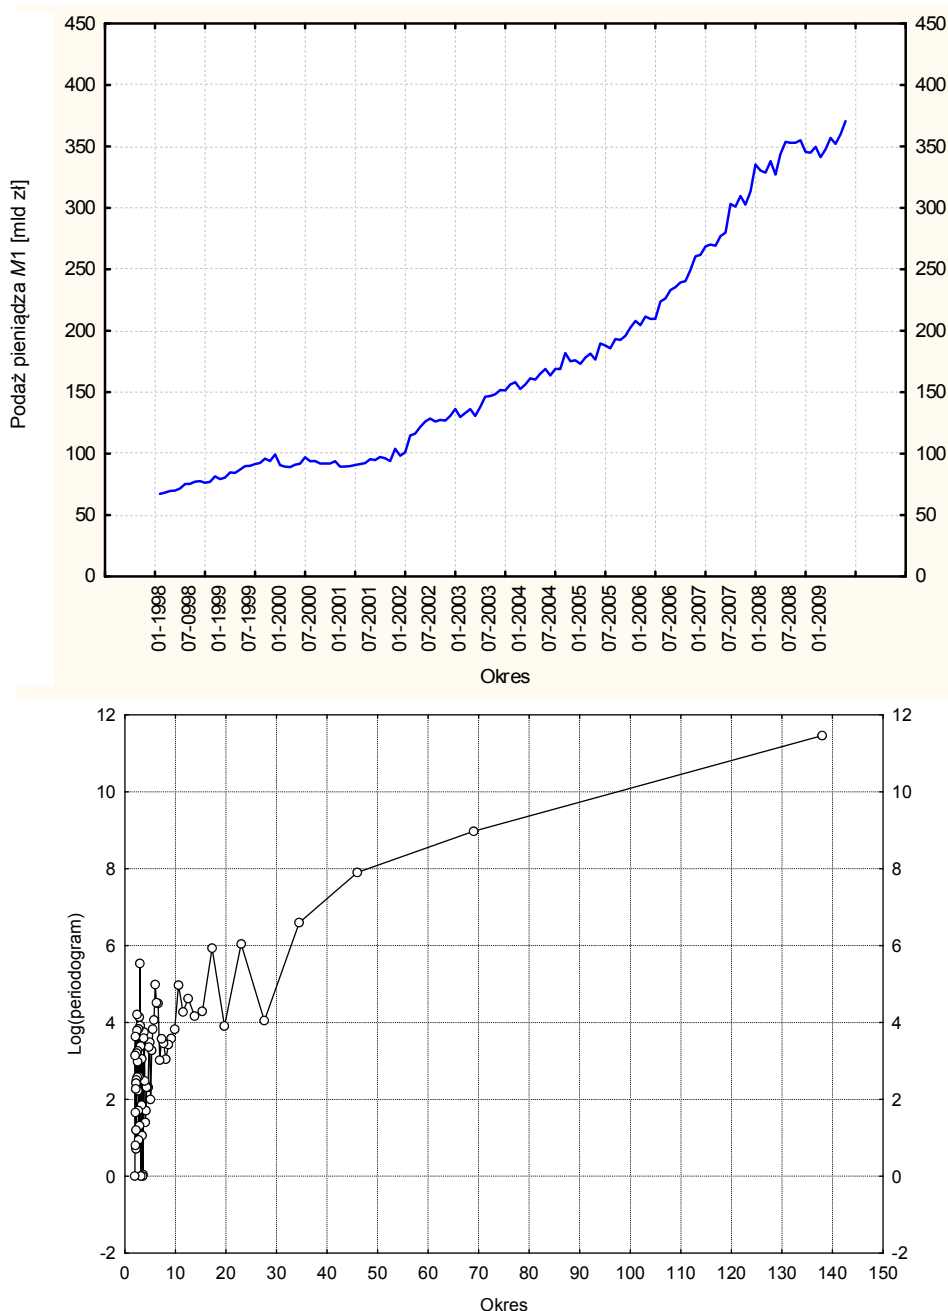
Jednak ciągle pierwszy parametr AR miał wartość większą od 1. Warto zauważyć, że wzbogacanie modelu o części SAR, SMA, lub SARMA z okresami sugerowanymi przez periodogram nie poprawiało modelu. Dopiero zróżnicowanie stopnia pierwszego tej cechy pozwoliło znaleźć model spełniający wszystkie założenia (tab. 3, rys. 11 i 12). Był to model ARIMA(1 1 0) i SMA(1) z okresem 12, wyrażony wzorem: $\Delta y_t = 0,4934\Delta y_{t-1} + 0,4455\varepsilon_{t-12} + \sigma$.



Rys. 11. Wykres autokorelacji i autokorelacji cząstkowej dla reszt z modelu ARIMA(1 1 0) i SMA(1) z okresem 12 dotyczącym stopnia inflacji w Polsce



Rys. 12. Kształt rozkładu reszt z modelu ARIMA(1 1 0) i SMA(1) z okresem 12 dotyczącym stopnia inflacji w Polsce

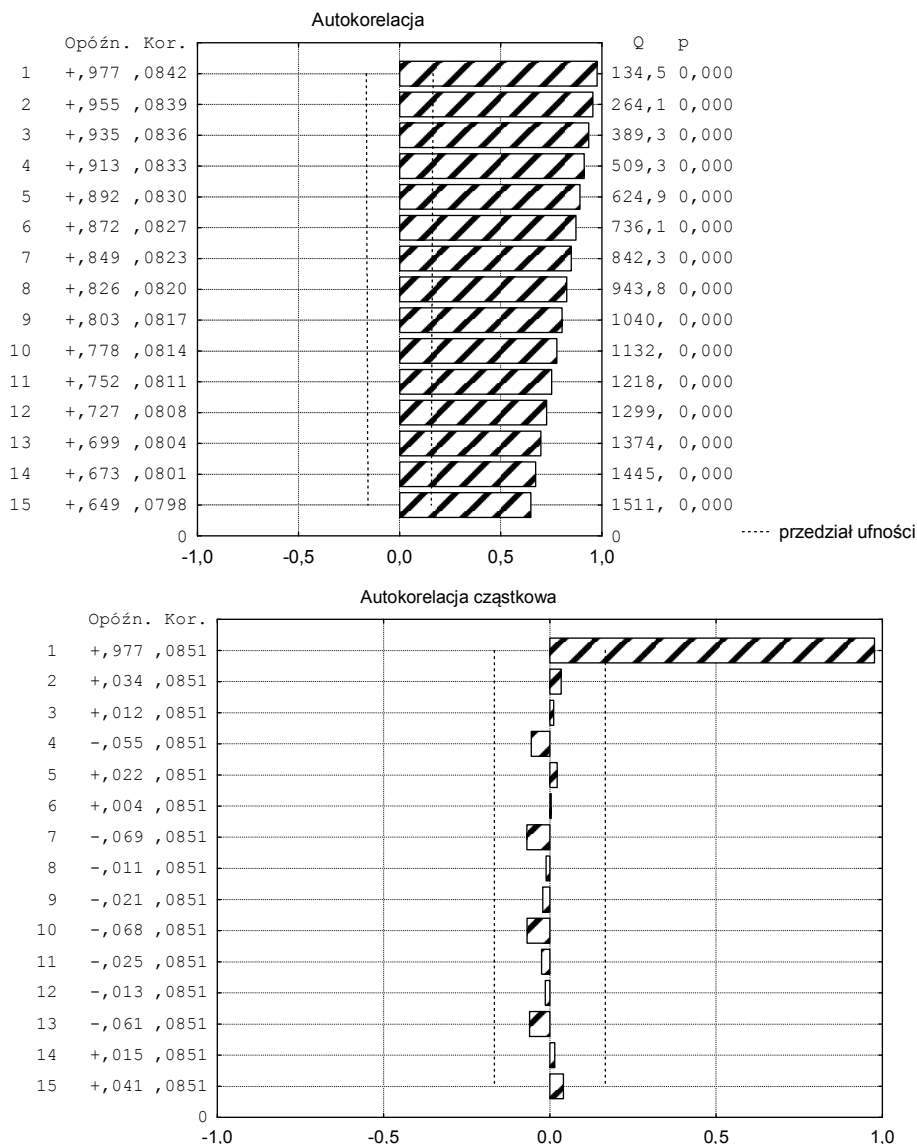


Rys. 13. Miesięczna podaż pieniądza w Polsce mierzona parametrem $M1$ oraz wykres analizy Fouriera (widmowej) i zlogarytmowane wartości periodogramu

Ostatnią ze zmiennych poddaną analizie była podaż pieniądza mierzona wskaźnikiem agregatowym $M1$ (gotówka w obiegu oraz depozyty). Zmienna ta w przybliżeniu miała trend rosnący (rys. 13), chociaż można w zmienności tej cechy wskazać dwa okresy występowania trendu stałego (pierwszy – od listopada 1999 r. do listopada 2001 r., drugi – od maja 2005 r. do kwietnia 2009 r.). Analiza Fouriera podaży pieniądza w Polsce wykazała (rys. 13), że wartości okresów, które należy wziąć pod uwagę, znajdują się przy liczbach 3, 6, 11, 12, 17, 23 i 34, 46.

Z kształtu zanikania słupków na rys. 14, przedstawiającego autokorelację i autokorelację cząstkową dla podaży pieniądza, można wnioskować, że należy zacząć poszukiwania modelu od AR rzędu 1. Model ten był statystycznie istotny, ale nie spełniał założeń braku istotnych autokorelacji i autokorelacji cząstkowych dla reszt. Dodatkowo ze względu na niestacjonar-

ność badanej cechy należało badany szereg poddać operacji różnicowania. Różnicowanie stopnia pierwszego doprowadziło badany szereg czasowy do stacjonarności. Modelem, który spełniał założenia, był (tab. 4 oraz rys. 15 i 16) model ARIMA(1 1 0) x SAR (2) z okresem 6, wyrażony następującym wzorem: $\Delta y_t = 1,9529 - 0,2257\Delta y_{t-1} + 0,2125\Delta y_{t-6} + 0,4035\Delta y_{t-12} + \sigma$.


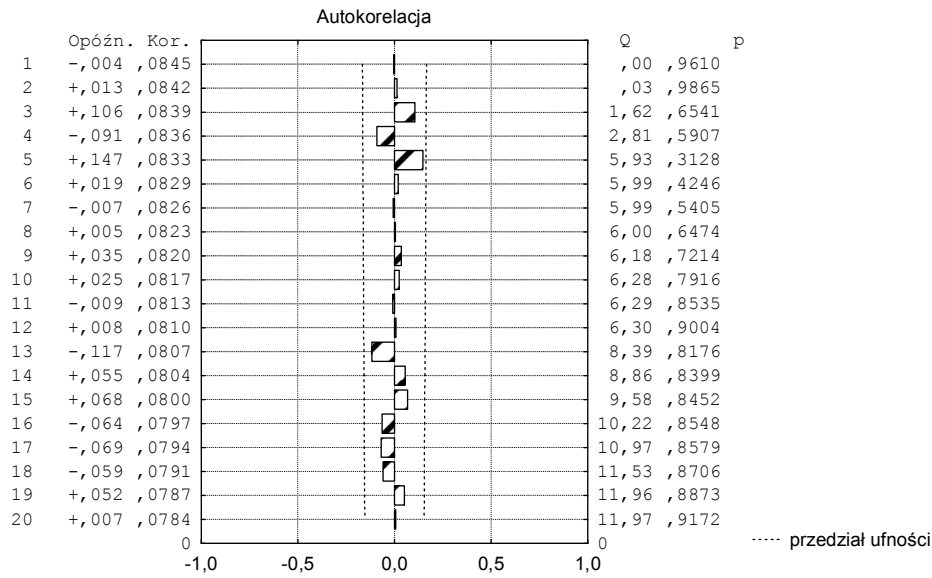


Rys. 14. Wykres autokorelacji i autokorelacji cząstkowej dla podaży pieniądza (M1) w Polsce

Tabela 4. Parametry modelu opisującego zmienność podaży pieniądza (M1) w Polsce

| | Parametr | Asymptotyczny błąd standardowy | Asymptotyczny $t(127)$ | p | Dolna granica 95-procentowy poziom ufności | Górna granica 95-procentowy poziom ufności |
|---------|-----------|--------------------------------|------------------------|----------|--|--|
| Stała | 1,952914 | 0,747400 | 2,61294 | 0,010010 | 0,474585 | 3,431243 |
| $P(1)$ | -0,225709 | 0,087767 | -2,57169 | 0,011219 | -0,399308 | -0,052110 |
| $Ps(1)$ | 0,212477 | 0,085917 | 2,47306 | 0,014657 | 0,042538 | 0,382417 |
| $Ps(2)$ | 0,403469 | 0,088830 | 4,54205 | 0,000012 | 0,227767 | 0,579171 |

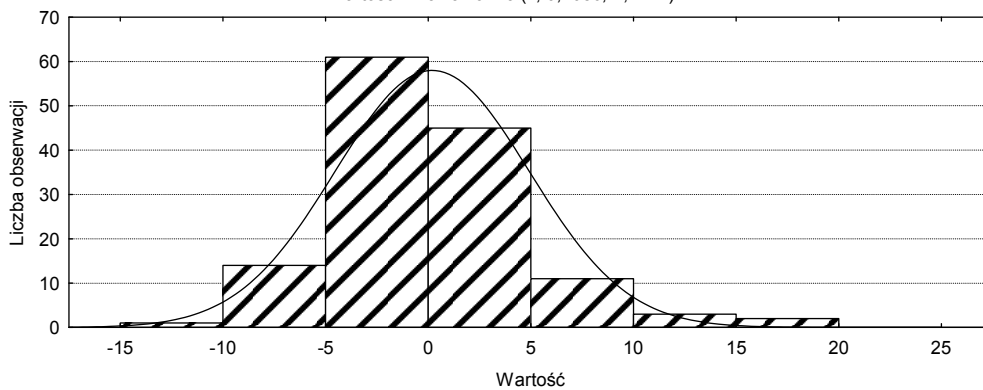
Przekształcenia: $D(1)$, model: $(1,1,0)(2,0,0)$, opóźnienia sezonowości: 6, resztowy $MS = 22,710$.



Rys. 15. Wykres autokorelacji i autokorelacji cząstkowej dla reszt z modelu ARIMA(6 1 0) i SAR(1) z okresem 12 dotyczącym podaży pieniądza (M1) w Polsce

Wartość: SW-W = 0,945; $p = 0,00003$; $D = 0,0955$; $p < 0,2000$; p -Lillieforsa $< 0,01$

Wartość = 137,5 normal(x; 0,1086; 4,7114)



Rys. 16. Kształt rozkładu reszt z modelu ARIMA(6 1 0) i modelu SAR(1) z okresem 12 dotyczącym podaży pieniądza (M1) w Polsce

PODSUMOWANIE

Rachunki narodowe są jednym z podstawowych narzędzi ekonomistów. Stanowią one stosunkowo pełny obraz gospodarki narodowej i zmian jej struktury w czasie. Dodatkowo są one spójne pod względem pojęć i klasyfikacji z innymi statystykami społecznymi i gospodarczymi. Daje to możliwość prowadzenia szerokich analiz społecznych i gospodarczych wykraczających poza zakres rachunkowości narodowej. Porównywalne dane, obejmujące od kilku do kilkunastu lat, umożliwiają obserwowanie długookresowych zjawisk zachodzących w gospodarce. Natomiast dzięki zgodności metodologicznej z innymi krajami możliwe staje się także prowadzenie porównań międzynarodowych (Lada 2008).

Na problem budowania modeli dla makroekonomicznych cech zwracało uwagę wielu badaczy (niektórych z nich wymieniono w Piśmiennictwie); podstawą do porównywania takich analiz powinna być uzyskana przez nich postać modelu.

Należy zauważyć, że postaci końcowe uzyskanych modeli różniły się od postaci sugerowanych w procesie identyfikacji. Z uwagi na ogólną dostępność komputerów procedury znajdowania modelu końcowego powinny przebiegać w sposób automatyczny poprzez rozpatrzenie wszystkich postaci modeli dla z góry zadanego rzędu krańcowego modelu i krańcowej wielkości okresu. Natomiast rozpatrywanych powinno być ostatecznie kilka modeli o najmniejszym MS , charakteryzujących się statystycznie istotnymi parametrami, brakiem autokorelacji i autokorelacji cząstkowych reszt oraz jednocześnie brakiem podstaw do odrzucenia hipotezy o normalności ich rozkładu.

Pewną niedogodnością programu Statistica PL jest brak możliwości generowania postaci modelu przez z góry zadane parametry, z uwzględnieniem składnika losowego, który może być losowo generowany przez zadany typ i parametry rozkładu. Analiza takich modeli na tle rzeczywistych danych wzbogaciłaby ich diagnostykę.

Na podstawie budowy uzyskanych modeli można zauważyć, że informacja o przyszłej wartości:

- 1) zmiany PKB zawarta jest w obecnej zmianie wartości PKB i 4, 5, 8 oraz 9 kwartale wcześniej;
- 2) inflacji zawarta jest w obecnej i wcześniejszej wartości inflacji oraz w błędzie prognozy dla wartości inflacji sprzed 12 obserwacji wcześniej;
- 3) ilości pieniądza na rynku ($M1$) zawarta jest w obecnej wartości $M1$ oraz w $M1$ z 6, 7, 12, 13 okresów wcześniejszych;
- 4) stopy bezrobocia zawarta jest w obserwacjach wcześniejszych (z opóźnieniem sięgającym nawet 74 miesięcy).

PIŚMIENNICTWO

Box G.E.P., Jenkins G.M. 1983. Analiza szeregów czasowych. Warszawa, PWN.

Chraślowska J., Nazarko J. 2003. Zastosowanie modeli ARIMA w prognozowaniu przychodów ze sprzedaży na przykładzie przedsiębiorstwa handlowego typu Cash&Carry. Taksonomia 10. Klasyfikacja i analiza danych, teoria i zastosowania, 222–232.

Dudek H. 2007. Prognozowanie skupu cen mięsa drobiowego za pomocą sezonowego modelu ARIMA. Stow. Ekonom. Rol. Agrobiz., Roczn. Nauk. 7 (5), 19–25.

- Lada K.** 2008. Znaczenie rachunków narodowych w analizach ekonomicznych, w: Rachunki narodowe Wybrane problemy i przykłady zastosowań. Warszawa, GUS, Departament Rachunków Narodowych, UŁ Wydział Ekonomiczno-Socjologiczny, 27–38, /www.stat.gov.pl/cps/rde/xbcr/gus/PUBL_rachunki_narodowe-wybr_probl_i_przyk_zastos.pdf, dostęp dn. 18.11.2010 r.
- Welfe A.** 1998. Ekonometria. Warszawa, PWE.
- Wyżnikiewicz B., Fundowicz J., Kowalska I., Lada K., Łaciński K., Peterlik M.** 2009. Stan i prognoza koniunktury gospodarczej. Kwartalne Prognozy Makroekonomiczne 62, Warszawa, Instytut Badań nad Gospodarką Rynkową Oddział w Warszawie, www.IBNGR.PLindex.php/pl/content/download/1276/13021/file/prognozy_09_02.pdf, dostęp dn. 18.11.2010 r.
- Zeliaś A.** 2004. przyczynek do dyskusji o trudnych problemach prognozowania ekonomicznego. Zesz. Nauk. USzczec. 394, Prace Katedry Ekonometri i Statystyki 15, 343–350.
- Główny Urząd Statystyczny.** Wskaźniki makroekonomiczne, www.stat.gov.pl/gus/wskazniki_makroekon_PLK_HTML.htm, dostęp dn. 18.11.2010 r.

