

**ZASTOSOWANIE MODELU ARIMA DO PROGNOZOWANIA  
WIELKOŚCI PRODUKCJI W PRZEDSIĘBIORSTWIE**

**APPLICATION OF ARIMA MODEL FOR FORECASTING PRODUCTION  
QUANTITY IN ENTERPRISE**

**Małgorzata GRZELAK**  
malgorzata.grzelak@wat.edu.pl  
<https://orcid.org/0000-0001-6296-7098>

Wojskowa Akademia Techniczna  
Wydział Logistyki  
Instytut Logistyki

**Streszczenie:** *Celem przedsiębiorstw produkcyjnych jest zaspokajanie potrzeb klientów, poprzez terminowe wytwarzanie wyrobów zgodnie z popytem występującym na rynku. Powyższe działania umożliwiające są przez prawidłowe sporządzanie prognoz potencjalnych zamówień. W poniższym artykule przedstawiono model ARIMA jako narzędzie wspierające planowanie wielkości produkcji w przedsiębiorstwie. Dokonano również oceny wiarygodności opracowanego modelu poprzez analizę reszt oraz ich autokorelacji i autokorelacji cząstkowych.*

**Abstract:** *The purpose of production companies is to meet the needs of customers by timely production of products in accordance with the demand on the market. The above activities are enabled by proper preparation of forecasts of potential orders. The following article presents a tool supporting production volume planning in an enterprise based on the ARIMA autoregressive model. The likelihood of the developed model was also evaluated by analyzing the residuals and their autocorrelations and partial autocorrelations.*

**Słowa kluczowe:** *model ARIMA, harmonogramowanie produkcji, gotowość, prognozowanie.*

**Keywords:** *ARIMA model, production scheduling, readiness, swimming baths, forecasting.*

## **WSTĘP**

Planowanie produkcji w przedsiębiorstwie stanowi kluczowy element w sterowaniu i kontroli działalności wytwórczej, określając sposób wykorzystania zasobów w celu otrzymania wyrobów gotowych. Harmonogramowanie przepływów surowców i materiałów wraz z terminami i wielkością produkcji opiera się na prognozach sprzedaży oferowanego asortymentu. Znajomość technik i narzędzi do estymacji powyższych wielkości oraz prawidłowe ich zastosowanie w firmie zapewnia prawidłowe funkcjonowanie systemu produkcyjnego, a co za tym idzie, osiągnięcie założonych celów działalności poprzez terminowe zaspokajanie potrzeb klientów.

Prawidłowe stosowanie metod predykcji umożliwia kształtowanie gotowości przedsiębiorców do realizacji przyjętych planów oraz zabezpieczania potrzeb generowanych przez rynek. Pojęcie gotowości ściśle związane jest z teorią eksploatacji obiektów technicznych (Żurek i in., 2017, 2343-2352; Borucka, 2018, 3-19), przez co należy ją rozumieć jako zdolność do utrzymywania się w stanie pozwalającym na realizację wymaganych funkcji i zadań.

W przedsiębiorstwach produkcyjnych odnosi się głównie do elementów i części parku maszynowego (Świdorski i in., 2019, 1-9), ale może również dotyczyć urządzeń, jako całościowych struktur niezawodnościowych (Borucka, 2018, 1073-1082). Najczęściej termin ten wykorzystywany jest przy charakteryzowaniu systemów o nagłych interwencjach, np. pogotowie ratunkowe (Borucka, 2018, s. 397-395), ale również może znaleźć zastosowanie w ogniach o stałych harmonogramach dostaw surowców i materiałów (Żurek i in., 2017, 2343-2352; Borucka, 2018, 13-23), do których zaliczyć należy firmy wytwarzające w środowisku produkcji na magazyn, czy tych realizujących zadania związane z przemieszczaniem (Borucka, 2014, 468-475).

Gotowość, w kontekście firm produkcyjnych, odnosi się głównie do utrzymania zdolności do zapewnienia płynności przepływów surowców i materiałów (Waśniewski, Borucka, 2011, 223-233) z wykorzystaniem środków transportowych w celu prawidłowego zasilenia systemu produkcyjnego. Realizacja powyższego ma miejsce przy wykorzystaniu analiz tej zdolności oraz czynników mogących negatywnie oddziaływać na ruch zasobów, w tym wypadków w ruchu drogowym (Skoczyński i in., 2018, 92 – 97; Świdorski, 2018, 651- 654; Borucka, 2018, 162-166) czy kongestii w ruchu miejskim (Mítkow, 2018, 501-526). Samo zapewnienie prawidłowości przepływów wymaga gotowości parku maszynowego, jak również człowieka jako użytkownika, którego stopień wykształcenia jest nieodłącznym elementem niezawodności całego systemu (Borucka, Wielgosik, 2016, 51-66; Borucka, Mikosz, 2008, 1-12).

Celem artykułu jest przedstawienie zastosowania modelu ARIMA do prognozowania wielkości produkcji w przedsiębiorstwie z branży tworzyw sztucznych, a także analiza jego wiarygodności na podstawie sprawdzenia normalności rozkładu reszt oraz funkcji ich autokorelacji.

## **1. ZASTOSOWANIE MODELU ARIMA DO PROGNOZOWANIA WIELKOŚCI PRODUKCJI**

Analiza przebiegu zjawisk gospodarczych przeprowadzana jest na podstawie szeregów czasowych, które definiowane są jako uporządkowany zbiór obserwacji statystycznych losowo zależnych od czasu (Cieślak, 2001). Umożliwia ona ustalenie natury badanego zjawiska, a także wyodrębnienie składowych systematycznych, wynikających ze stale oddziałujących czynników (tj. tendencji rozwojowej, stałego poziomu zmiennej czy składowej okresowej), a także elementów przypadkowych, które ujmowane są w formie funkcji matematycznych. Powyższe działania umożliwiają realizację prognozowania przyszłych (kolejnych) wartości szeregu czasowego.

Klasyczne modele ekonometryczne zakładają, że zjawiska opisywane są za pomocą równań funkcji zależnych od pewnych, wyodrębnionych czynników. Natomiast w modelach szeregów czasowych przyjmuje się, że opisywane procesy stochastyczne generowane są przez siebie same, tj.

na podstawie analiz opóźnień w ich przebiegu (Witkowska, 2005). Wśród modeli służących do opisu powyższych procesów szczególne miejsce zajmują modele stacjonarnych szeregów ARMA (Autoregressive Moving Average) oraz niestacjonarnych ARIMA (Autoregressive integrated moving average model). Są to modele oparte na zjawisku autokorelacji, powstałe przez integrację modelu autoregresyjnego AR (Autoregressive model) oraz modelu średniej ruchomej MA (Moving average).

Procesy stacjonarne cechują się stałą wariancją (Czyżycki i in., 2011), a ich wartości w poszczególnych chwilach oscylują wokół stałej wartości zmiennej. Do predykcji zmiennej wykorzystywane są modele ARMA zakładające, że wartość prognozowana w czasie  $t$  zależy od przeszłych jej wielkości oraz od różnic między przeszłymi wartościami rzeczywistymi zmiennej prognozowanej a jej wartościami uzyskanymi z modelu – błędów prognoz, zgodnie ze wzorem nr 1.

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p} + \varepsilon_t \beta_0 + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \beta_2 \varepsilon_{t-2} - \dots - \beta_q \varepsilon_{t-q} \quad (1)$$

gdzie:

$y_t$  – wartość zmiennej prognozowanej,

$\alpha, \beta$  – parametry modelu,

$\varepsilon$  – błąd (reszta) modelu.

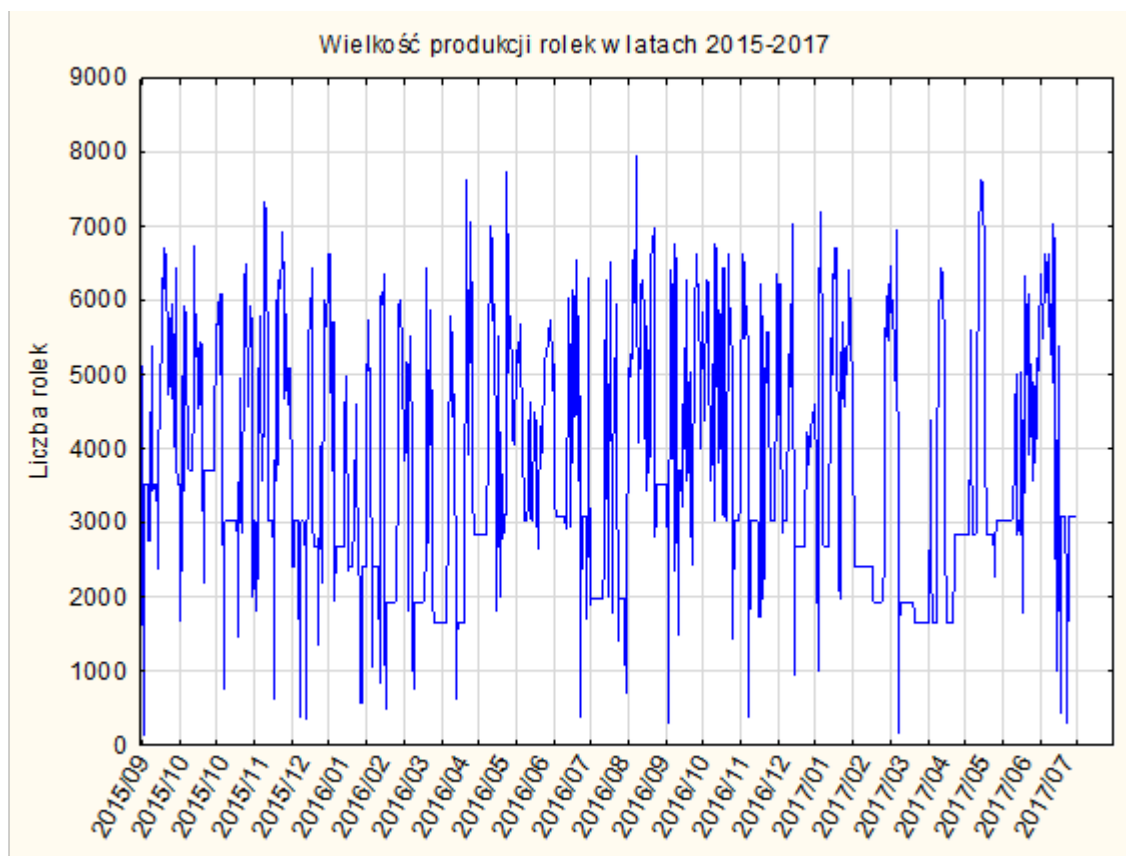
Wiele zjawisk gospodarczych ma niestacjonarny charakter i wymaga do prognozowania stosowania modelu ARIMA. Użycie litery  $i$  znaczy, że badany szereg czasowy poddano różnicowaniu, doprowadzając do stacjonarności. Niestacjonarność spowodowaną występowaniem wahań sezonowych eliminuje się poprzez różnicowanie sezonowe. Wówczas wykorzystywany jest model SARIMA (Seasonal ARIMA), który pozwala na modelowanie danych sezonowych (Dittmann i in., 2011). Konstruuje się go, uzupełniając model ARIMA o składnik wynikający z sezonowości analizowanego procesu. Wybór właściwego modelu do predykcji należy poprzedzić sprawdzeniem stanu szeregu czasowego. Niestacjonarność względem średniej wykrywa się poprzez identyfikację tendencji rozwojowej lub wyznaczenie funkcji autokorelacji, która w szeregach niestacjonarnych powinna nie maleć wraz ze wzrostem opóźnienia  $k$ .

## **2. CHARAKTERYSTYKA OBIEKTU BADAŃ**

Przedmiotem badań jest przedsiębiorstwo produkcyjne zajmujące się produkcją foliowych worków na śmieci z tworzyw sztucznych, w tym polietylenu dużej gęstości HDPE. Produkcja realizowana jest z surowców pozyskiwanych z odzysku odpadów foliowych i ich przemianie w granulaty do ponownego zastosowania, wspierając działania proekologiczne i ochronę środowiska (Mikosz, Borucka, 2008, 1-12). Wytwarzanie worków na śmieci odbywa się w ramach dwóch procesów, w pierwszym wytwarzany jest granulaty, natomiast w drugim następuje jego transformacja w wyrób końcowy w trzech głównych etapach:

- mieszanie – przygotowanie odpowiedniej mieszanki przez operatora zgodnie z kartą produktu,
- wytłaczanie i rozdmuch – podgrzanie mieszanki do wysokich temperatur, a następnie jej topienie i „wydmuchanie” w specjalnej głowicy na zewnątrz w postaci tzw. balonu, który za pomocą odpowiednich części maszyny zostaje uformowany w tzw. rękaw foliowy i nawinięty na tekturową lub metalową tuleję. Gotowa rolka rękawa foliowego jest zdejmowana z maszyny przez operatora wytłaczarek i transportowana w pobliże rolomatów,
- cięcie i zgrzewanie – folia jest rozwijana, a podczas przechodzenia poprzez poszczególne sekcje maszyny, wykonywany jest zgrzew oraz perforacja na każdym worku. Ostatnia sekcja maszyny (nawijarka) nawija zadaną ilość worków na rolkę, a operator maszyny zakłada papierową etykietę i pakuje ją do kartonu.

Poniższa analiza zostanie przeprowadzona w oparciu o dane dotyczące wielkości produkcji worków na śmieci 20 l, stanowiącą próbę 700 obserwacji zgromadzonych w latach 2015-2017. Pierwszym krokiem była wizualna inspekcja badanego szeregu w oparciu o wykres liniowy rzeczywistych obserwacji wielkości produkcji worków na śmieci (rys. 1).



Rys. 1. Wielkość produkcji rolek worków na śmieci w latach 2015-2017

Źródło: Opracowanie własne.


Na jej podstawie można stwierdzić, że w badanym szeregu nie występuje tendencja rozwojowa oraz nie są widoczne obserwacje odstające. Uzupełnieniem powyższej analizy jest tabela

zawierająca podstawowe miary statystyki opisowej (tab. 1) oraz wykres ramkowy ukazujący miesięczny rozkład wielkości produkcji (rys. 2).

Tabela 1. Podstawowe miary statystyk opisowych zgrupowane wg miesiąca

Miesiąc	Liczba obserwacji	Średnia [liczba osób]	Mediana [liczba osób]	Minimum [liczba osób]	Maksimum [liczba osób]	Odch.std [liczba osób]	Wsp.zmn. [%]
styczeń	62	3781,65	2694,97	360	7200	1651,42	43,66
luty	57	3478,07	2417,68	560	6732	1624,08	46,69
marzec	62	3041,37	1943,97	175	6975	1791,69	58,91
kwiecień	60	2706,84	1657,25	630	6450	1683,53	62,19
maj	62	3943,94	2857,25	1830	7740	1736,78	44,03
czerwiec	60	4018,40	3943,50	1800	6350	1049,14	26,10
lipiec	62	4158,96	3630,00	300	7050	1696,01	40,77
sierpień	31	2958,89	1994,03	704	6525	1629,15	55,06
wrzesień	60	4524,52	4070,50	140	7963	1623,07	35,87
październik	62	4682,17	4642,00	1500	6775	1269,31	27,11
listopad	60	4043,13	3127,00	396	6776	1618,31	40,03
grudzień	62	4178,86	3816,00	375	7360	1604,60	38,40
<b>RAZEM</b>	<b>700</b>	<b>3831,91</b>	<b>3488,00</b>	<b>140</b>	<b>7963</b>	<b>1685,27</b>	<b>43,98</b>

Źródło: Opracowanie własne.




Rys. 2. Średnia wielkość produkcji w poszczególnych miesiącach w roku

Źródło: Opracowanie własne.

Powyższe rezultaty ukazują dużą zmienność średnich w poszczególnych miesiącach oraz w odniesieniu do przeciętnej wartości dla wszystkich obserwacji. Największe wskazania odnotowano w październiku oraz wrześniu. Na podstawie wykresu ramkowego trudno wnioskować o sezonowości w szeregu czasowym. Nieregularność procesu produkcyjnego wynika zarówno z faktu, że firma prowadzi produkcję na magazyn, a także z fluktuacji poziomu popytu na rynku. Dodatkowo, spadek wytwarzania może być spowodowany awariami maszyn czy braku dostępności surowców i materiałów.

Kolejnym krokiem jest analiza empiryczna rozkładów czasów trwania analizowanych stanów eksploatacyjnych (rys. 3). Pozwala to na dopasowanie ich do teoretycznego rozkładu, ale również jest elementem oceny próby badawczej. W omawianym przypadku rozkład wygląda jak połączenie dwóch rozkładów normalnych. Natomiast wielomodalność sugeruje nałożenie na siebie dwóch podprocesów, co może utrudnić analizę i wpłynąć na wiarygodność prognozy. Ponieważ na histogramie nie ma wyraźnej granicy pomiędzy dwoma rozkładami, a merytoryczna wiedza o procesie nie pozwala na ich wyodrębnienie, zdecydowano o dalszej analizie danych w pierwotnej postaci.

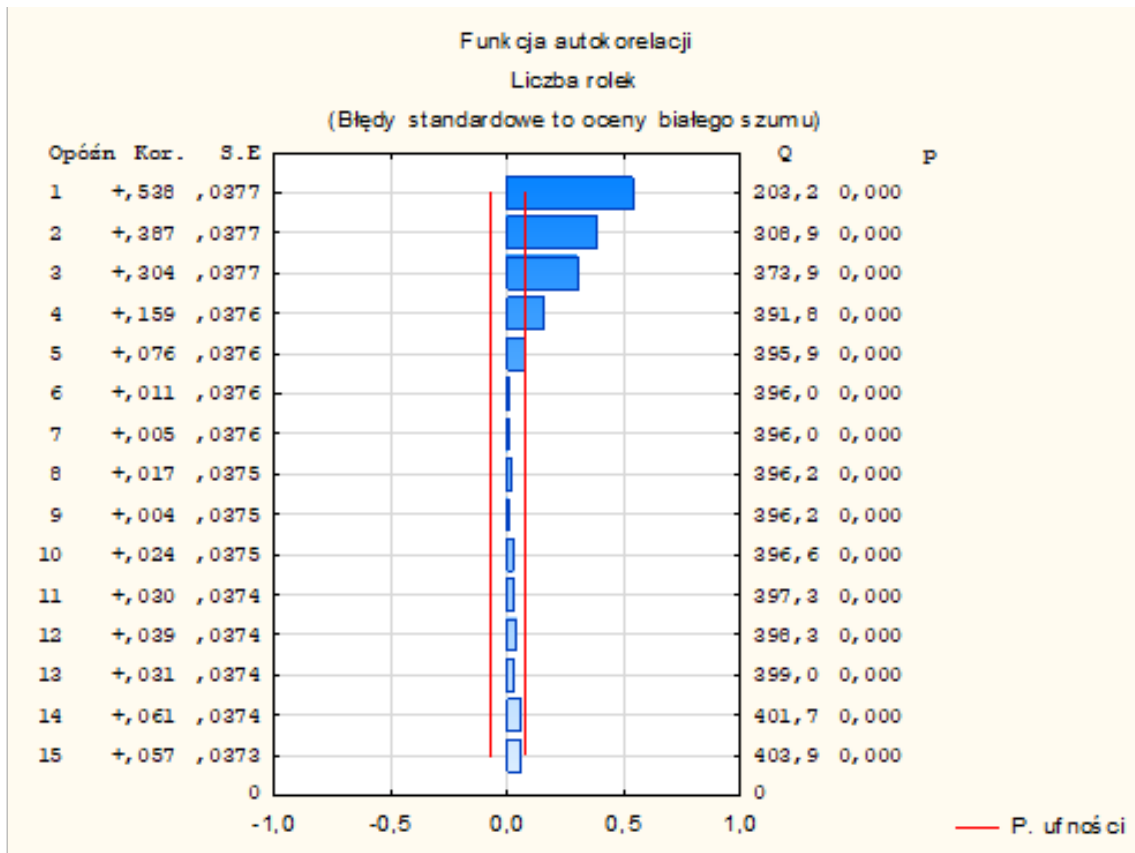


Rys. 3. Histogram badanego szeregu

Źródło: Opracowanie własne.

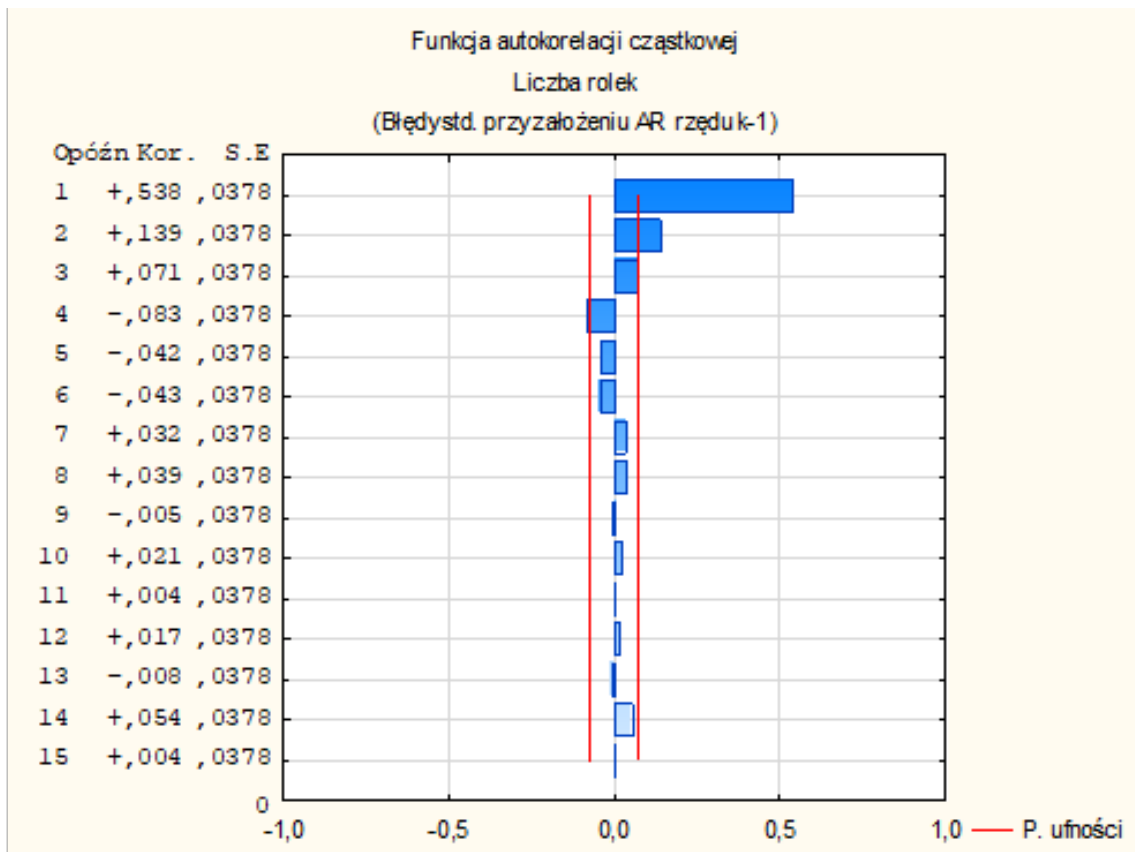
Estymację modelu ARIMA rozpoczęto od analizy funkcji autokorelacji ACF (rys. 4) i autokorelacji cząstkowej PACF (rys. 5), co ma na celu wspieranie doboru parametrów modelu.

Ponadto pozwala na ustalenie, czy badany szereg jest stacjonarny, co warunkuje stosowanie metody ARIMA jako możliwej do stosowania przy procesach stacjonarnych lub sprowadzanych do stacjonarnych.



Rys. 4. Wykres autokorelacji ACF badanego szeregu

Źródło: Opracowanie własne.



Rys. 5. Wykres autokorelacji cząstkowej PACF badanego szeregu

Źródło: Opracowanie własne.

Funkcja autokorelacji ACF opada wykładniczo i przyjmując duże wartości przy opóźnieniach 1-4, natomiast funkcja autokorelacji cząstkowej PACF szybko wygasa, osiągając duże wartości dla pierwszych dwóch opóźnień. Sugeruje to, że wstępna postać modelu powinna mieć cztery parametry średniej ruchomej (q) oraz dwa parametry autoregresyjne (p). Na podstawie wykresu liniowego (rys. 1) oraz wykresów funkcji autokorelacji i autokorelacji cząstkowej potwierdzono także stacjonarność szeregu. Estymację modelu rozpoczęto od modelu ARIMA (2, 0, 4) który jednak okazał się niemożliwy do zastosowania, dlatego metodą *testing down*, tj. zmniejszając kolejno wartości parametrów, poszukiwano najlepszego rozwiązania.

Wybrane wyniki estymacji zostały zagregowane w tabeli nr 2, a wszystkie prezentowane parametry są statystycznie istotne.

Tabela 2. Parametry wybranych modeli ARIMA

	Model (1,0,1)	Model (0,0,1)	Model (1,0,0)	Model (2,0,0)
Stała	3831,257	3834,584	3835,286	3831,569
p(1)	0,718		0,538	0,463
p(2)				
q(1)	0,257	-0,426		0,139
MS	1,982	2,238	2,022	1,986
	nie występują istotne	występują istotne	występują istotne	nie występują istotne



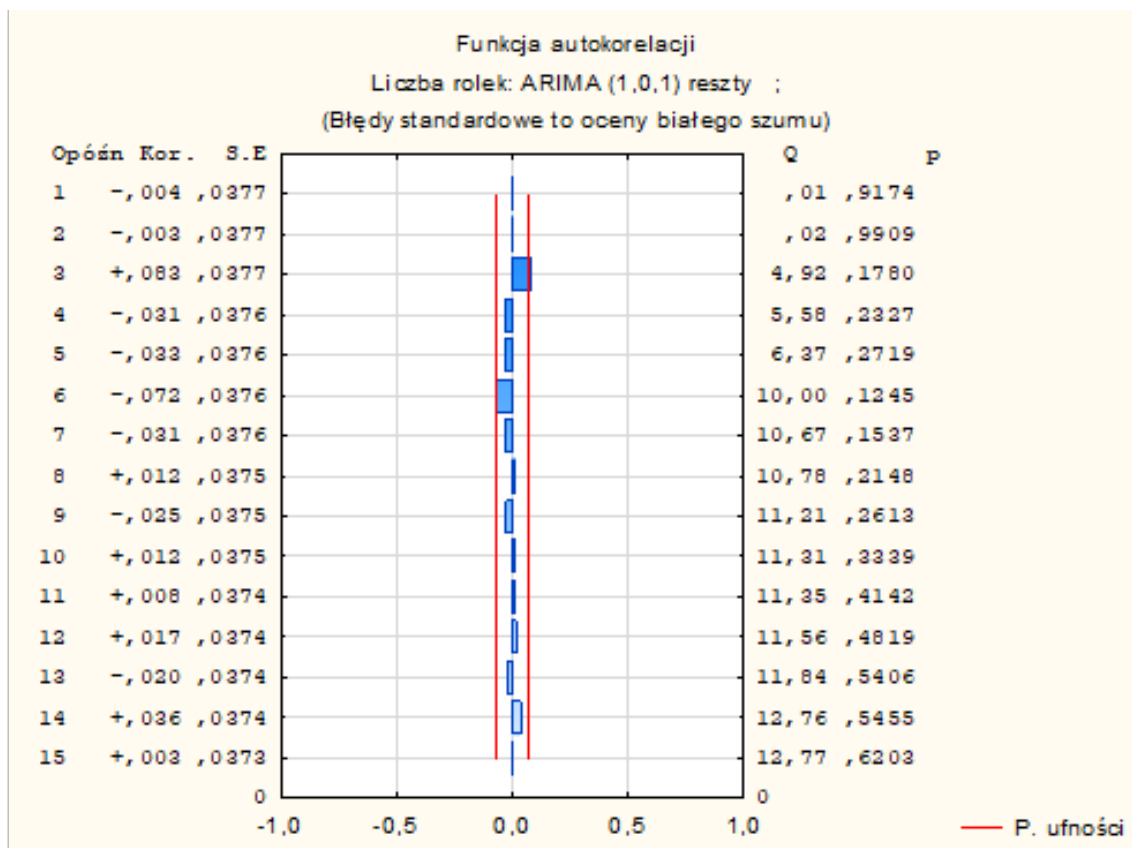
	autokorelacje reszt	autokorelacje reszt	autokorelacje reszt	autokorelacje reszt
--	------------------------	------------------------	------------------------	------------------------

Źródło: Opracowanie własne.

### 3. OCENA ZAPROPONOWANEGO MODELU

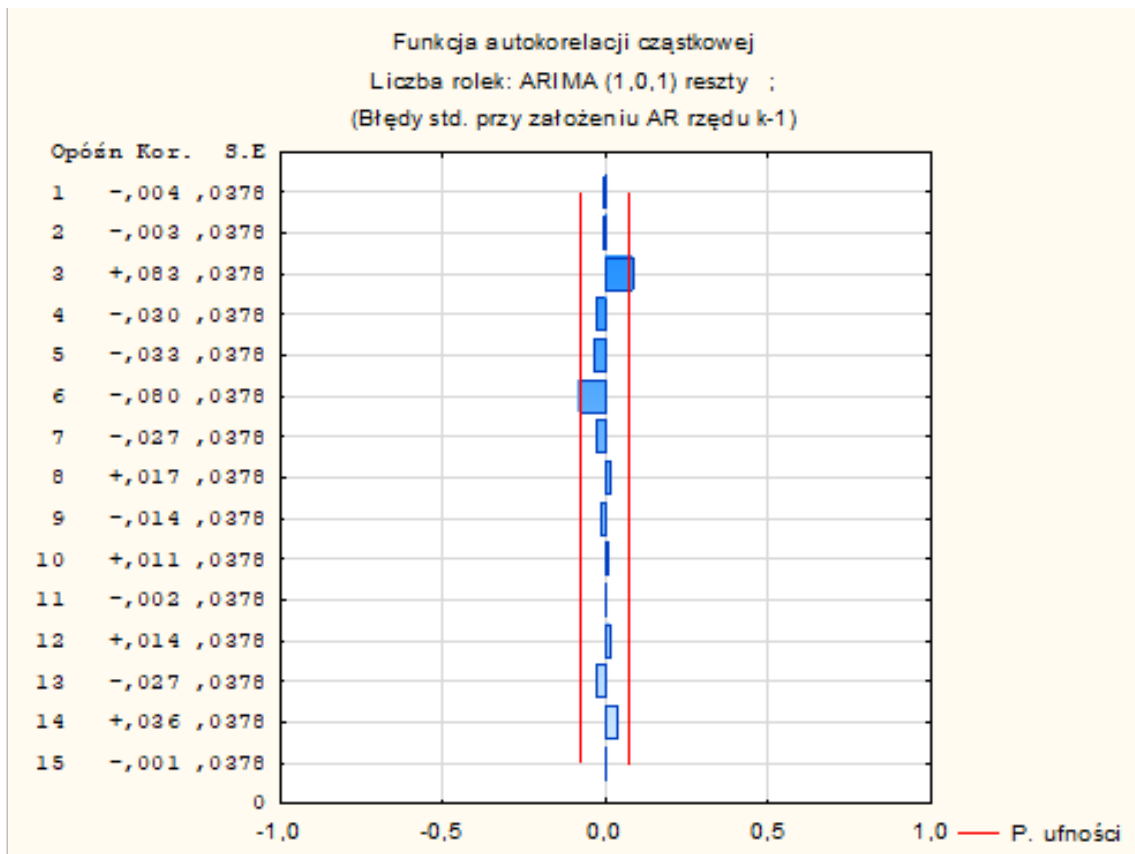
Oceniając zaproponowane modele, w pierwszej kolejności należy sprawdzić, czy estymowane parametry są statystycznie istotnie różne od zera, ponieważ parametr nieistotny informuje o tym, że zmienna nie wpływa na dopasowanie modelu i może zostać w nim pominięta. We wszystkich powyższych modelach warunek ten został spełniony. Kolejnym kryterium jest wartość błędu średniego MS oraz przede wszystkim diagnostyka rozkładu reszt, które we właściwie skonstruowanym modelu powinny cechować się losowością i symetrią.

Tylko w dwóch z zaproponowanych modeli nie odnotowano istotnych zależności elementów funkcji autokorelacji i autokorelacji cząstkowej, dlatego to spośród nich wybrano ten, który miał niższą wartość błędu średniego – ARIMA (1,0,1) i poddano dalszej analizie, w której zbadano stacjonarność i normalność rozkładu reszt. W tym celu ponownie posłużono się funkcją autokorelacji i autokorelacji cząstkowej (rys. 6 oraz rys. 7). Wykresy funkcji ACF i PACF pokazują brak statystycznie istotnych autokorelacji i autokorelacji cząstkowych, co pozwala uznać model za prawidłowy.



Rys. 6.. Wykres autokorelacji ACF reszt modelu

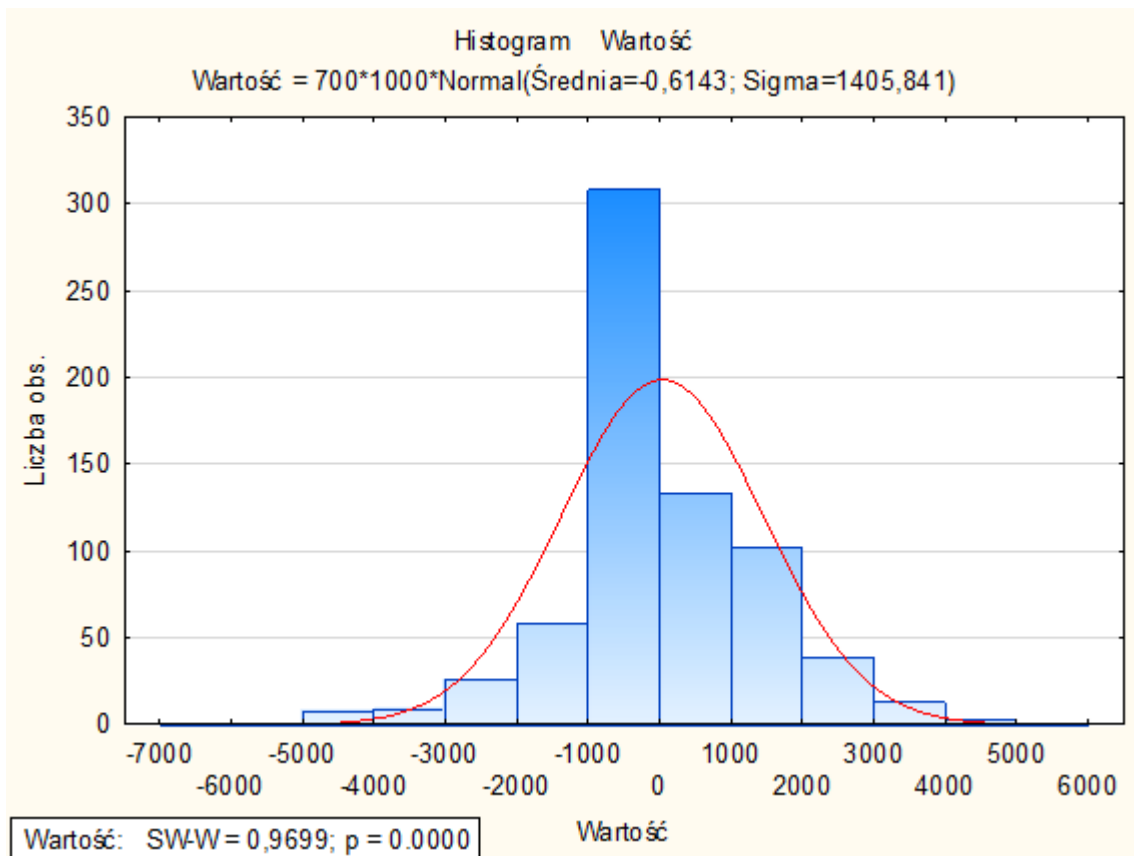
Źródło: opracowanie własne.



Rys. 7. Wykres autokorelacji cząstkowej PACF reszt modelu


Źródło: Opracowanie własne.

Natomiast mało satysfakcjonujący wynik otrzymano z badania rozkładu reszt pod kątem zgodności z rozkładem normalnym, co zostało potwierdzone negatywnym wynikiem testu S-W. Jest on niesymetryczny z wyraźnie zaznaczoną wartością modalną (rys. 8).




Rys. 8. Wykres normalności rozkładu reszt  
Źródło: opracowanie własne.

Na niesymetryczność rozkładu wpływają liczne przeszacowania prognozy, widoczne na rys. 9 i przedstawione na przybliżonym wykresie na rys. 10.



Rys. 9. Wykres badanego szeregu i prognozy

Źródło: Opracowanie własne.



Rys. 10. Przybliżony wykres badanego szeregu i prognozy

Źródło: opracowanie własne.

Powyższe wykresy wykazały, że zaproponowany model nie dostarcza wysoce wiarygodnych prognoz. Udostępnione przez przedsiębiorstwo dane nie były wystarczające. Zbiórcze wartości dla danego dnia okazały się mieszaniną co najmniej dwóch podprocesów i dopiero po ich wyodrębnieniu można spodziewać się satysfakcjonujących wyników.

## **PODSUMOWANIE**

Podsumowując, w artykule zaprezentowano możliwość zastosowania modelu ARIMA do prognozowania wielkości produkcji w przedsiębiorstwie. Bazując na analizie szeregów czasowych, badających zależność zmiennej od czasu, zaprezentowano prognozy kształtowania się wielkości wytwarzania w najbliższej przyszłości. Niestety, ocena wiarygodności opracowanego modelu wykazała brak normalności rozkładu jego reszt, co spowodowane jest uzyskaniem niewystarczająco satysfakcjonujących danych od firmy. Prognozowanie na wyłącznie na podstawie czasu może powodować wyraźne błędy w estymacji wielkości produkcji, ponieważ warunkowana ona jest również przez inne czynniki, w tym te dotyczące systemu eksploatacji maszyn (analiza występowania awarii oraz przestoje związane z czynnościami obsługowymi) oraz parametry związane z nieterminowym zasilaniem w surowce i materiały niezbędne do wytwarzania, a które nie zostały ujęte w modelu.

## **LITERATURA**

- [1] BORUCKA, A. (2013). Analiza polskiego transportu samochodowego. *Systemy logistyczne wojsk*, (39), 13-23.
- [2] BORUCKA, A. (2013). Funkcjonowanie wojskowych oddziałów gospodarczych w nowym systemie logistycznym sił zbrojnych. *Logistyka*, 6, 39-48.
- [3] BORUCKA, A. (2014). Przewóz osób w Polsce w świetle zmian legislacyjnych. *Logistyka*, 6, 468-475.
- [4] BORUCKA, A. (2018). Analysis of the effectiveness of selected demand forecasting models. *Współczesna Gospodarka*, 9(2), 41-55.
- [5] BORUCKA, A. (2018). Application of ARIMA Models for the Analysis of Utilization Process of Military Technical Objects. *Logistics and Transport*, 37, 13-22.
- [6] BORUCKA, A. (2018). Forecasting of fire risk with regard to readiness of rescue and fire-fighting vehicles. *Interdisciplinary Management Research XIV', Croatia*, 397-395.
- [7] BORUCKA, A. (2018). Markov models in the analysis of the operation process of transport means. In *Proceedings of the ICTTE International Journal For Traffic And Transport Engineering Conference, Belgrad* (pp. 1073-1082).
- [8] BORUCKA, A. (2018). Model of the operation process of aircraft in the transport system. In *Proceedings of the ICTTE International Journal For Traffic And Transport Engineering Conference, Serbia* (pp. 22-30).

- [9] BORUCKA, A. (2018). Risk Analysis of Accidents in Poland Based on ARIMA Model. *Transport Means*, 162-166.
- [10] BORUCKA, A. (2018). Three-state Markov model of using transport means. *Business Logistics In Modern Management*, 3-19.
- [11] BORUCKA, A., & MIKOSZ, B. (2008). Organizacja gospodarki odpadami w siłach zbrojnych na tle zmian militarnych i nowych wyzwań stawianych polskiej armii. *Archiwum Gospodarki Odpadami i Ochrony Środowiska*, 8, 1-12.
- [12] BORUCKA, A., & MITKOW, S. (2018). Mathematical model of travel times related to a transport congestion: an example of the capital city of Poland–Warsaw. *Business Logistics In Modern Management*, 501-526.
- [13] CIESLAK, M. (2001). Prognozowanie gospodarcze. *Metody i zastosowania*. Warszawa: PWN.
- [14] CZYŻYCKI, R., & KLÓSKA, R. (EDS.). (2011). *Ekonometria i prognozowanie zjawisk ekonomicznych w przykładach i zadaniach*. Economicus.
- [15] Dittmann, I., Dittmann, P., Szabela-Pasierbińska, E., & Szpulak, A. (2011). *Prognozowanie w zarządzaniu sprzedażą i finansami przedsiębiorstwa*. Wolters Kluwer.
- [16] KLÓSKA, R., HUNDERT, M., & CZYŻYCKI, R. (2007). *Wybrane zagadnienia z prognozowania*. Economicus.
- [17] ŚWIDERSKI, A., & BORUCKA, A. (2018). Mathematical Analysis of Factors Affecting the Road Safety in Selected Polish Region, Transport Means. In *Proceedings of the 22nd International Scientific Conference part II, Lithuania* (pp. 651-654).
- [18] ŚWIDERSKI, A., BORUCKA, A., & SKOCZYŃSKI, P. (2018, October). Characteristics and assessment of the road safety level in Poland with multiple regression model. In *Transport Means', Proceedings of the 22nd International Scientific Conference, Part I, Lithuania* (pp. 92-97).
- [19] ŚWIDERSKI, A., BORUCKA, A., JACYNA-GÓLDA, I., & SZCZEPAŃSKI, E. (2019). Wear of brake system components in various operating conditions of vehicle in the transport company. *Eksplatacja i Niezawodność*, 1(21), 1-9. [dx.doi.org/10.17531/ein.2019.1.1](https://doi.org/10.17531/ein.2019.1.1)
- [20] WAŚNIEWSKI, T., & BORUCKA, A. (2011). Sieciowe rozwiązania w łańcuchu dostaw w oparciu o technologię radiowej identyfikacji towarów. *Systemy Logistyczne Wojsk*, (37), 235-245.
- [21] WIELGOSIK, M., BORUCKA, A. (2016). Istota i znaczenie służby przygotowawczej i szkolenia rezerw, *Systemy Logistyczne Wojsk*, 45, 51-66.
- [22] WITKOWSKA, D. (2005). *Podstawy ekonometrii i teorii prognozowania*. Oficyna ekonomiczna.
- [23] ŻUREK, J., ZIÓLKOWSKI, J., & BORUCKA, A. (2017). A method for determination of combat vehicles availability by means of statistic and econometric analysis, Safety and Reliability. *Theory and Applications, ESREL*, 2925-2934.
- [24] ŻUREK, J., ZIÓLKOWSKI, J., & BORUCKA, A. (2017). Application of Markov processes to the method for analysis of combat vehicle operation in the aspect of their availability and readiness. *Safety and Reliability. Theory and Applications, ESREL*, 2343-2352.
- [25] ŻUREK, J., ZIÓLKOWSKI, J., & BORUCKA, A. (2017). Research of automotive vehicles operation process using the Markov model, Safety and Reliability. *Theory and Applications, ESREL*, 2353-2362.