

PROGNOZOWANIE JEDNĄ METODĄ TRZYDZIESTU DWÓCH GRUP ZMIENNYCH

THE FORECASTING OF DATA OF THIRTY-TWO GROUPS OF VARIABLES WITH ONE METHOD

Bartosz KOZICKI

bartosz.kozicki@wat.edu.pl
<https://orcid.org/0000-0002-9424-377X>

Wojskowa Akademia Techniczna
Wydział Bezpieczeństwa, Logistyki i Zarządzania
Instytut Logistyki

Jarosław TOMASZEWSKI

jarekt7@wp.pl
<https://orcid.org/0000-0003-2365-0797>

Ministerstwo Obrony Narodowej

Artur KOSZAREK

artur1201@wp.pl
<https://orcid.org/0000-0002-6426-0587>

Inspektorat Wsparcia Sił Zbrojnych

Streszczenie: W artykule poruszono problem badawczy dotyczący prognozowania jedną metodą trzydziestu dwóch grup zmiennych. Badania rozpoczęto od pozyskania danych pierwotnych w formie macierzy z strony internetowej Eurostatu. Dane pierwotne dotyczyły liczby lotnisk w trzydziestu dwóch państwach Europy w latach 2008-2017. Dalszym etapem było przeprowadzenie transformacji danych zawartych w macierzy w jeden szereg czasowy (badawczy). Szereg badawczy został poddany analizie i ocenie. Uzyskane oceny przeprowadzonych analiz pozwoliły wykryć tendencję, które stały się przesłanką do wyboru metod prognozowania. Wybrano dwie metody. Szereg badawczy został podzielony na dwie części na bazie których, zostały poddane analizie i ocenie dwie wybrane metody do prognozowania poprzez zastosowanie średniego bezwzględnego błędu prognozy. Najlepszą metodą wykonano prognozowanie szeregu badawczego na trzydzieści dwa przyszłe okresy.

Abstract: In this article, the author raises the research problem related to the forecasting of thirty-two groups of variables with one method. The research was initiated by gathering original data as a matrix from the Eurostat website. Original data concerned the number of airports in thirty-two European countries between 2008-2017. The next stage was the transformation of data included in the matrix into a time (research) series. The research series was analyzed and evaluated. The obtained results of analyses enabled the detection of a trend which became a premise for the choice of forecasting methods. Two methods were chosen. The research series was divided into two parts based on which these two forecasting methods were analyzed and evaluated with the application of a mean absolute forecasting error. The forecasting of the research series for thirty-two future periods was conducted with the best method.

Słowa kluczowe: infrastruktura lotniskowa, prognozowanie

Keywords: airport infrastructure, forecasting

WSTĘP

Prognozowanie należy nadal do ważnych aspektów w zakresie roli i znaczenie planowania w podejmowaniu decyzji w ujęciu marko- i mikroekonomicznym.

Celem głównym opracowania jest wykonanie prognozowania jedną metodą trzydziestu dwóch grup zmiennych. **Przedmiotem badań** są zmienne zawarte w grupach dotyczące ilości lotnisk w poszczególnych państwach Europy, które obsługują powyżej 15 000 pasażerów rocznie. Natomiast **podmiotem badań** są trzydzieści dwa rozpatrywane państwa Europy (grupy).

W artykule zastosowano **metody badawcze** w postaci analizy literatury, która dotyczy zagadnień związanych z infrastrukturą lotniskową i prognozowaniem. Dodatkowo użyto **techniki badawczej** w postaci programu komputerowego Statistica. Co więcej zastosowano następujące **narzędzia badawcze**: wykres kwartylowy, autokorelacja, autokorelacja cząstkowa, regresja wieloraka, histogram, test Shapiro-Wilka.

Artykuł składa się ze wstępu, trzech punktów merytorycznych, podsumowania i wniosków.

1. ANALIZA LITERATURY

W literaturze infrastrukturą określa się podstawowy kapitał społeczny zawarty w drogach oraz innych systemach transportowych i komunikacyjnych. Infrastruktura transportowa umożliwia przemieszczanie osób i ładunków. Szczególnym rodzajem infrastruktury są lotniska. Dysponują one różnym wyposażeniem i wielkością (Ciesielki, 1999). W artykule poddane prognozowaniu zostały tylko te, które w ciągu roku obsługują powyżej 15 000 pasażerów.

Krytyczna analiza literatury pozwala na stwierdzenie, że prognozowanie jest różnie interpretowane. Zdaniem R. Griffina to jeden ze środków wykorzystywanych podczas planowania (Griffin, 2018). Jest ono niezwykle ważne z punktu poprawnego zarządzania przedsiębiorstwem lub organizacją. Zdaniem P. Dittmanna jest racjonalnym, naukowym przewidywaniem przyszłych zdarzeń (Dittmann, 2016). Chcąc działać efektywnie na rynku i odnosić sukcesy, należy starać się przewidywać przyszłe sytuacje, które mogą zagrażać lub przyczyniać się do dalszego rozwoju. Prognozowanie wymaga poprawnej analizy i oceny szeregów czasowych danych retrospektywnych. Szereg czasowy w literaturze jest definiowany jako nielosowa funkcję $x(t)$, będącą realizacją procesu stochastycznego $X(w, t)$ dla ustalonego zdarzenia elementarnego w_0 (Kot, Jakubowski, Sokołowski, 2011). Uzyskane oceny z przeprowadzonej analizy szeregów czasowych pozwalają dokonać wyboru właściwej metody do prognozowania na przyszłość. Metody prognozowania podlegają analizie i ocenie.

Niezwykle istotne z punktu tematu artykułu jest prognozowanie wielu grup zmiennych dotyczących ilości lotnisk w trzydziestu dwóch państwach Europy w ujęciu dynamicznym jedną

metodą, która umożliwiłaby uzyskanie poprawnych wyników w krótkim czasie. Badania rozpoczęto od analizy danych pierwotnych pozyskanych z strony internetowej Eurostatu.

2. ANALIZA I OCENA DANYCH

W tabeli 1 przedstawiono dane pozyskane ze strony internetowej Eurostatu (dane pierwotne) dotyczące liczby lotnisk obsługujących rocznie powyżej 15 000 pasażerów w trzydziestu dwóch państwach Europy w latach 2008-2017.


Tabela 1. Dane pierwotne dotyczące liczby lotnisk obsługujących powyżej 15 000 pasażerów przez rok w trzydziestu dwóch państwach Europy w latach 2008-2017

Państwa	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
Belgium	5	5	5	5	5	5	5	5	5	5
Bulgaria	5	5	4	4	4	4	4	4	4	4
Czechia	4	5	5	5	5	5	5	5	5	5
Denmark	6	10	10	5	10	10	8	8	8	8
Germany	75	77	78	41	77	38	38	42	40	41
Estonia	7	7	3	7	7	7	1	2	2	2
Ireland	9	11	11	11	9	9	8	8	7	7
Greece	39	39	39	39	39	39	33	33	34	33
Spain	40	42	42	42	48	41	48	37	38	38
France	78	63	132	64	130	64	62	62	62	62
Croatia	9	9	7	7	7	7	7	7	7	7
Italy	45	43	39	39	38	37	38	37	37	35
Cyprus	2	2	2	2	2	2	2	2	2	2
Latvia	4	4	4	2	2	1	1	1	1	1
Lithuania	3	3	4	4	4	4	3	3	3	4
Luxembourg	1	1	1	1	1	1	1	1	1	1
Hungary	3	5	5	5	5	5	4	4	4	3
Malta	1	1	1	1	1	1	1	1	1	1
Netherlands	5	5	5	5	5	5	5	5	5	5
Austria	6	6	6	6	6	6	6	6	6	6
Poland	10	10	10	10	10	10	12	12	12	12
Portugal	10	10	10	10	18	16	13	13	13	13
Romania	9	9	9	9	9	13	11	11	12	11
Slovenia	3	3	3	3	3	3	1	1	1	1
Slovakia	6	6	5	6	6	6	4	4	4	4
Finland	29	29	23	24	23	22	19	18	17	18

Państwa	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
Sweden	33	32	32	32	33	40	33	31	30	30
United Kingdom	55	55	54	55	54	53	45	42	43	42
Iceland	14	20	20	20	20	16	1	1	1	7
Norway	110	54	54	54	54	54	49	47	47	42
Switzerland	7	7	7	7	7	7	6	6	6	6
Turkey	41	39	43	47	48	52	48	51	51	50

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Dane przedstawione w tabeli 1 dotyczące liczby lotnisk wykazują pewne tendencje w grupach państw. W większości widoczny jest brak trendu, w innych zazwyczaj obserwuje się trend o charakterze malejący. Zgodnie z celem opracowania podjęto próbę prognozowania jedną metodą na 2019 trzydziestu dwóch grup zmiennych. Do realizacji tego celu zbudowano z macierzy (tabela 1) szereg, który przedstawiono na rysunku 1. Składa się on z 320 elementów. Szereg powstał przez połączenie dziesięciu kolumn lat w pionie (od 2008 do 2017). Powstały szereg nazwano badawczym (rys. 1).




Rys. 1. Wykres liniowy danych pierwotnych dotyczących liczby lotnisk obsługujących powyżej 15 000 pasażerów przez rok w trzydziestu dwóch państwach Europy w latach 2008-2017 po transformacji

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

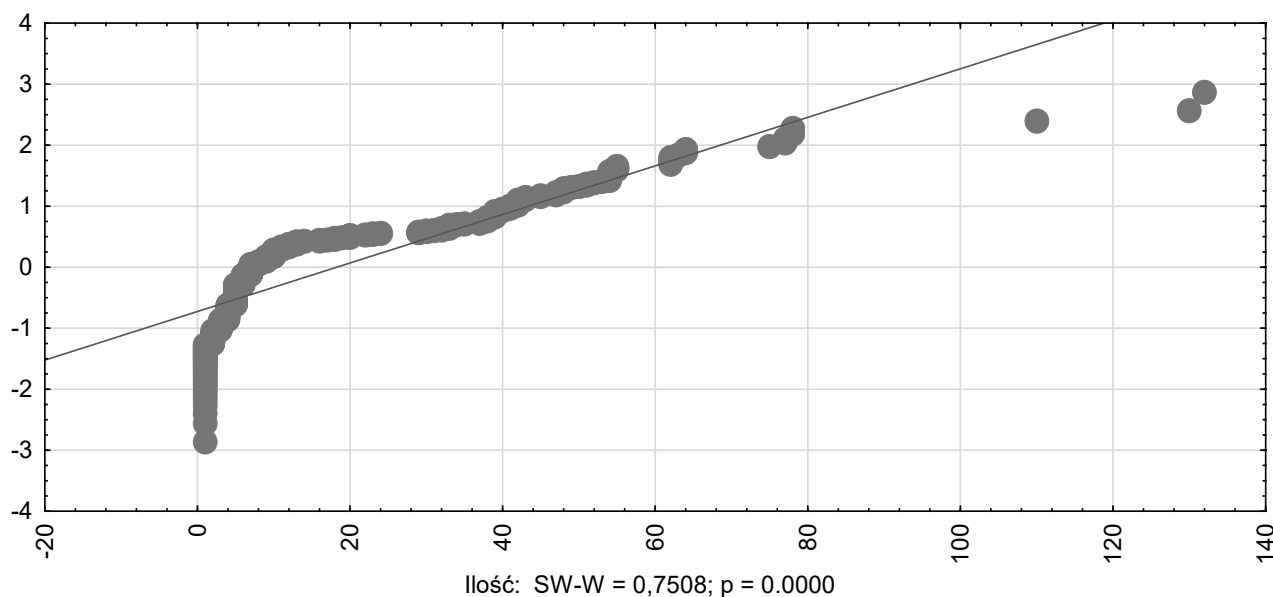
Oceną obserwacji wzrokowej rysunku 1 jest wykrycie tendencji co trzydzieści dwie obserwacje i bardzo słabego trendu malejącego, który nakreślono linią czerwoną i opisano wzorem w stopce.

Następnie, nowo powstały szereg badawczy został poddany analizie i ocenie. Pierwszym etapem badania było przeprowadzenie analizy i oceny rozkładu. Do tego celu użyto następujących narzędzi badawczych w postaci: histogramu (rys. 2) i wykresu normalności z testem Shapiro-Wilka (rys. 3).



Rys. 2. Histogram danych pierwotnych


Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.



Rys. 3. Wykres normalności danych pierwotnych

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.


Na podstawie rysunków 2 i 3 stwierdzono, że szereg badawczy nie ma rozkładu normalnego. Kwantyle odbiegają od nakreślonej linii. Histogram wskazuje na istnienie wartości odstających i ekstremalnych. Stało się to przesłanką do użycia kolejnego narzędzia badawczego w postaci wykresu ramka-wąsy (rys. 4).



Rys. 4. Wykres ramka-wąsy danych pierwotnych


Źródło: Opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Na rysunku 4 zaobserwowano istnienie dwóch pozycji, jako wartości ekstremalne i pięciu odstających. Dalszy etapem analiz jest poszukiwanie zależności w opóźnieniach szeregu czasowego badawczego. Do tego celu użyto: autokorelacji (rys. 5) i autokorelacji cząstkowej (rys. 6).



Rys. 5. Autokorelacja danych pierwotnych

Źródło: Opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.



Rys. 6. Autokorelacja cząstkowa danych pierwotnych

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Zastosowanie autokorelacji (rys. 5) i autokorelacji cząstkowej (rys. 6) wskazuje na zaobserwowanie zależności w opóźnieniach szeregu czasowego badawczego. Stało się to bezpośrednią przesłanką do zbudowania modelu zerojedynkowego w celu potwierdzenia istniejących zależności. Do budowy modelu użyto trzydziestu czterech predyktorów w tym zmiennych: t , t^2 , $\ln t$, trzydziestu jeden państw jako zmienne zerojedynkowe – bez Malty. Zbudowany model to macierz złożona z 10 880 zmiennych. Istotne predyktory, których prawdopodobieństwo wystąpienia było mniejsze od poziomu istotności zestawiono w tabeli 2.


Tabela 2. Model zerowyjedynekowy regresji wielorakiej

N=320	R= ,94604769 R ² = ,89500623 Popraw. R2= ,88982561					
	Błąd standardowy estymacji: 7,1834					
	b*	Bl. std.	b	Bl. std.	t(304)	p
W. wolny			7,70666	0,871190	8,84614	0,000000
t	-0,085292	0,018635	-0,01995	0,004359	-4,57707	0,000007
Finlandia	0,144016	0,018798	17,88495	2,334445	7,66133	0,000000
Francja	0,589962	0,018793	73,26574	2,333880	31,39224	0,000000
Niemcy	0,402344	0,018795	49,96598	2,334131	21,40667	0,000000
Grecja	0,257883	0,018794	32,02584	2,333956	13,72169	0,000000
Islandia	0,062364	0,018801	7,74480	2,334782	3,31714	0,001020
Włochy	0,275436	0,018793	34,20564	2,333837	14,65640	0,000000
Norwegia	0,420854	0,018802	52,26475	2,334911	22,38404	0,000000
Polska	0,051416	0,018795	6,38519	2,334044	2,73568	0,006591
Portugalia	0,066071	0,018795	8,20514	2,334108	3,51532	0,000506
Rumunia	0,047711	0,018796	5,92509	2,334180	2,53841	0,011635
Hiszpania	0,297501	0,018794	36,94579	2,333914	15,82997	0,000000
Szwecja	0,227921	0,018799	28,30490	2,334549	12,12435	0,000000
Turcja	0,344678	0,018804	42,80465	2,335193	18,33024	0,000000
Wielka Brytania	0,366582	0,018800	45,52485	2,334662	19,49955	0,000000

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

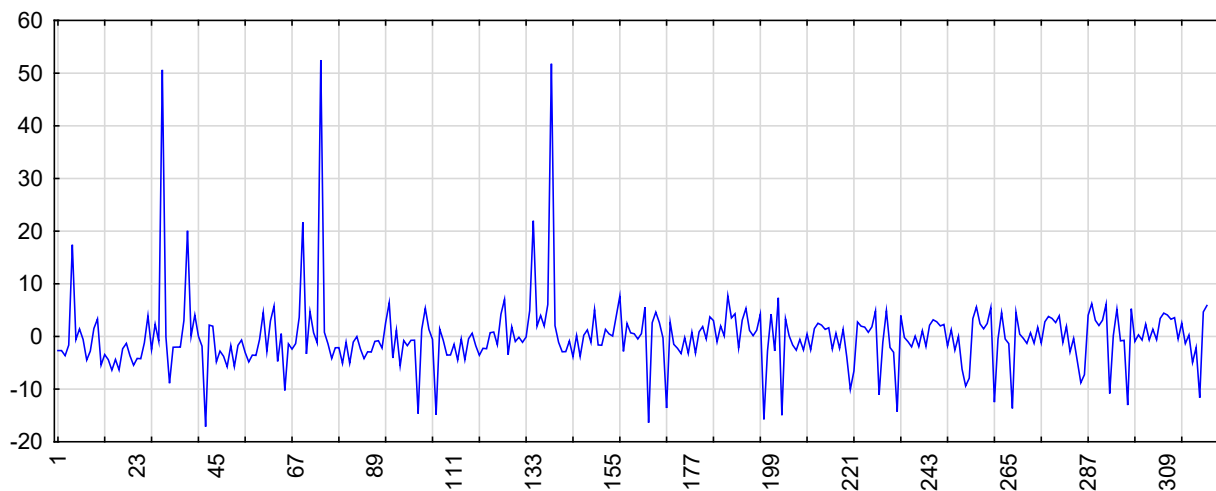
W zbudowanym model zerowyjedynekowy regresji wielorakiej (tabela 2) było piętnaście istotnych predyktorów do których zaliczono zmienne: t i zerowyjedynekowe dla czternastu państw. Potwierdza to istnienie tendencji w analizowanym szeregu badawczym. Co więcej zbudowany model był dobrze dopasowany. Wielokrotny R² wyniósł 0,9.

Dalszym etapem badań było przeprowadzenie analizy i oceny reszt zbudowanego modelu regresji wielorakiej. Do tego celu użyto następujących narzędzi badawczych: wykres wartości przewidywanych i obserwowanych (rys. 7), wykres liniowy reszt modelu (rys. 8), histogram (rys. 9), wykres normalności z testem Shapiro-Wilka (rys. 10), autokorelacja (rys. 11), autokorelacja cząstkowa (rys. 12).




Rys. 7. Wykres wartości przewidywanych i obserwowanych
Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Na podstawie rysunku 7 stwierdzono dobre dopasowanie wartości przewidywanych i obserwowanych.




Rysunek 8. Wykres liniowy reszt modelu zerojedynkowego regresji wielorakiej
Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Reszty przedstawione na rysunku 8 są dodatnie i ujemne o krótkich wycieczkach. Może to być przesłanką występowania zjawiska białego szumu.




Rys. 9. Histogram reszt modelu zerowego jedynkowego regresji wielorakiej
Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.



Rys. 10. Wykres normalności z testem Shapiro-Wilka reszt modelu zerowego jedynkowego regresji wielorakiej

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.


Zastosowanie histogramu (rys. 9) i wykresu normalności z testem Shapiro-Wilka (rys. 10) wskazują na brak rozkładu normalnego analizowanych danych dotyczących reszt.



Rys. 11. Autokorelacja reszt modelu zerojedynkowego regresji wielorakiej

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:

http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.



Rys. 12. Autokorelacja cząstkowa reszt modelu zerojedynkowego regresji wielorakiej


Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:

http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Zastosowanie autokorelacji (rys. 11) i autokorelacji cząstkowej (rys. 12) wykazuje zjawisko białego szumu.

Na podstawie wszystkich analiz reszt modelu zerojedynkowego regresji wielorakiej stwierdzono, że zbudowany model został wykonany poprawnie.


Wykryte zależności w postaci tendencji, która powtarza się co 32 okresy, jak również istnienie słabego trendu, stały się przesłankami do próby sprowadzenia szeregu badawczego do postaci stacjonarnej. W tym celu wykonano różnicowanie na poziomie 1; 32 i logarytmowanie (rys. 13).




Rys. 13. Sprowadzanie do postaci stacjonarnej szeregu czasowego pierwotnego

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Obserwacja wzrokowa rysunku 13 pozwala na stwierdzenie, że szereg badawczy po przekształceniu jest stacjonarny. W celu dokładnej weryfikacji stacjonarności szeregu badawczego po przekształceniach użyto dwóch narzędzi badawczych w postaci: autokorelacji (rys. 14) i autokorelacji cząstkowej (rys. 15).



Rys. 14. Autokorelacja szeregu czasowego pierwotnego sprowadzonego do postaci stacjonarnej
 Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.




Rys. 15. Autokorelacja cząstkowa szeregu czasowego pierwotnego sprowadzonego do postaci stacjonarnej

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Zastosowanie autokorelacji (rys. 14) i autokorelacji cząstkowej (rys. 15) wskazują, że widoczne jest zjawisko białego szumu. Tym samym potwierdzono, że szereg czasowy badawczy po przekształceniach jest stacjonarny.

Ocena sposobu przekształceń szeregu badawczego do postaci stacjonarnej będzie przesłanką do budowy modelu do prognozowania typu SARIMA.

W skutek krytycznej analizy literatury i na podstawie zaobserwowanych zależności wybrano dwie metody do prognozowania analizowanych danych badawczych do których zaliczono: metodą wygładzania wykładniczego Holta-Wintera, oraz model SARIMA. Podjęto również decyzję o analizie i ocenie dwóch wybranych metod prognozowania pod kątem wyboru lepszej. Stało się to przesłanką do podziału szeregu czasowego badawczego na dwie części (rys. 16).



Rys. 16. Podział szeregu czasowego pierwotnego na dwie części: szereg czasowy uczący – 288 i szereg czasowy testowy - 32


Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Szereg badawczy na rysunku 16 został podzielony na dwie części: uczącą złożoną z 288 elementów i testową z 32 elementów.

Dalszym etapem badania było wykonanie prognozowania szeregu uczącego na trzydzieści dwa przyszłe okresy (ilość elementów szeregu testowego).

3. PROGNOZOWANIE

Jako pierwszą zastosowano metodą wykładniczego Holta-Wintersa. Wyniki prognozy przedstawiono na rysunku 17.



Rys. 17. Prognozowanie metodą Holta-Wintersa szeregu uczącego na trzydzieści dwa przyszłe okresy

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Oceną wykonanej prognozy metodą Holta-Wintersa jest stwierdzenie zachowania tendencji w analizowanych danych retrospektywnych.

Dalszym etapem było zbudowanie modelu SARIMA. Istotne predyktory użyte do budowy modelu SARIMA zostały przedstawione w tabeli 3.

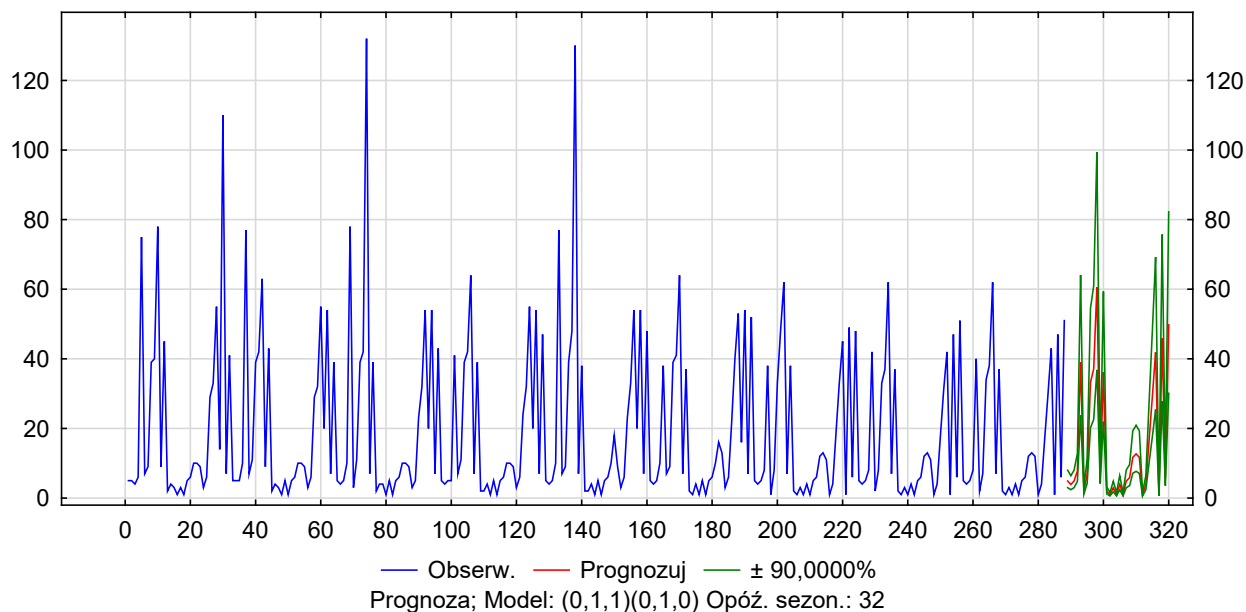
Tabela 3. Ocena parametrów modelu SARIMA szeregu uczącego

	Parametr	Asympt.	Asympt.	p	Dolna gr	Górna gr
q(1)	0,967708	0,040024	24,17825	0,00	0,888887	1,046529

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Istotnym predyktorem była zmienna q. Parametr q wyniósł 0,97. Postać modelu SARIMA była następująca (0,1,1)(0,1,0).

Wyniki prognozy modelem SARIMA (0,1,1)(0,1,0) szeregu uczącego na trzydzieści dwa przyszłe okresy przedstawiono na rysunku 18.



Rys. 18. Prognozowanie szeregu uczącego modelem SARIMA (0,1,1)(0,1,0) na trzydzieści dwa przyszłe okresy

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Obserwacja wzrokowa rysunków 17 i 18 pozwala na stwierdzenie, że prognoza uzyskana z modelu SARIMA jest lepsza od Holta-Wintersa. Dla celów badawczych przeprowadzono analizę (tabela 4) średniego bezwzględnego błędu procentowego – MAPE wykonanych prognoz.

Tabela 4. Analiza błędów prognozy

	MAPE HW	MAPE SARIMA
ŚREDNIA	0,2143627	0,0707634

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Oceną analizy przedstawionej w tabeli 4 jest stwierdzenie, że najlepszą metodą prognozowania był model SARIMA, gdzie MAPE było najmniejsze i wyniosło 7,08%.

Uzyskana ocena z analizy MAPE stała się przesłanką do wyboru do prognozowania szeregu badawczego na trzydzieści dwa przyszłe okresy.

Pierwszy etapem było zbudowanie modelu SARIMA. Istotne predyktory zestawiono w tabeli 5.

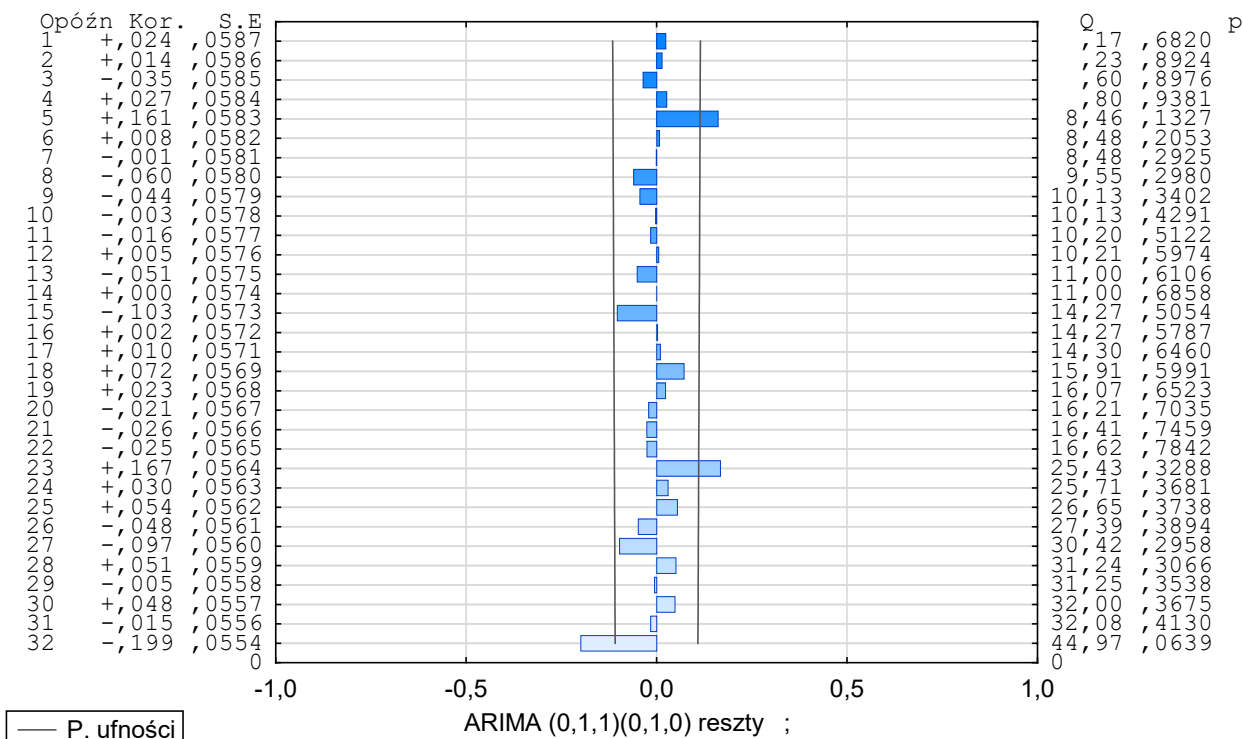
Tabela 5. Parametry modelu SARIMA (0,1,1)(0,1,0) szeregu pierwotnego

	Parametr	Asympt.	Asympt.	p	Dolna gr	Górna gr
q(1)	0,962990	0,024156	39,86570	0,00	0,915444	1,010536

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Istotnym predyktorem była zmienna q. Jej parametr wyniósł 0,96.


Następnie przeprowadzono analizę i ocenę reszt zbudowanego modelu SARIMA. Do tego celu użyto następujące narzędzia badawcze: autokorelacja (rysunek 18), autokorelacja cząstkowa (rys. 19), histogram (rys. 20) i wykres normalności (rys. 21).



Rys. 19. Autokorelacja reszt modelu SARIMA (0,1,1)(0,1,0) szeregu pierwotnego

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:

http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.




Rys. 20. Autokorelacja cząstkowa reszt modelu SARIMA (0,1,1)(0,1,0) szeregu pierwotnego

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:

http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.


Na podstawie zastosowanej autokorelacji (rys. 18) i autokorelacji cząstkowej (rys. 20) stwierdzono istnienie zjawiska białego szumu.



Rys. 21. Histogram reszt modelu SARIMA (0,1,1)(0,1,0) szeregu pierwotnego


Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:

http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.



Rys. 22. Wykres normalności reszt modelu SARIMA (0,1,1)(0,1,0) szeregu pierwotnego
Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Na podstawie rysunku 21 i 22 stwierdzono, że rozkład reszt prognozy modelu SARIMA jest zbliżony do rozkładu normalnego. Tym samym przyjęto, że zbudowany model jest poprawny. Dalszym etapem było wykonanie prognozowania modelem SARIMA szeregu czasowego badawczego (rys. 23-24 i tabela 6).




Rys. 23. Prognoza modelem SARIMA (0,1,1)(0,1,0) szeregu pierwotnego na trzydzieści dwa przyszłe okresy – rok 2018

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Na podstawie rysunku 23 zaobserwowano zachowania w uzyskanej prognozie (kolor niebieski) tendencji danych retrospektywnych szeregu badawczego, oznaczonych kolorem czerwonym.

Dla celów badawczych szczegółowe wyniki prognozy zestawiono na wykresie słupkowym (rys. 24) i w tabeli 6.



Rysunek 24. Wykres słupkowy prognozy modeliem SARIMA (0,1,1)(0,1,0) szeregu pierwotnego dla trzydziestu dwóch państw Europy – rok 2018

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej: http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Tabela 6. Prognoza modeliem SARIMA danych pierwotnych dotyczących liczby lotnisk, które obsługują powyżej 15 000 pasażerów rocznie na 2018 rok

Państwa	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018
Belgium	5	5	5	5	5	5	5	5	5	5	5
Bulgaria	5	5	4	4	4	4	4	4	4	4	4
Czechia	4	5	5	5	5	5	5	5	5	5	5
Denmark	6	10	10	5	10	10	8	8	8	8	8
Germany	75	77	78	41	77	38	38	42	40	41	43
Estonia	7	7	3	7	7	7	1	2	2	2	2
Ireland	9	11	11	11	9	9	8	8	7	7	7
Greece	39	39	39	39	39	39	33	33	34	33	35
Spain	40	42	42	42	48	41	48	37	38	38	40
France	78	63	132	64	130	64	62	62	62	62	65
Croatia	9	9	7	7	7	7	7	7	7	7	7

Państwa	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018
Italy	45	43	39	39	38	37	38	37	37	35	37
Cyprus	2	2	2	2	2	2	2	2	2	2	2
Latvia	4	4	4	2	2	1	1	1	1	1	1
Lithuania	3	3	4	4	4	4	3	3	3	4	4
Luxembourg	1	1	1	1	1	1	1	1	1	1	1
Hungary	3	5	5	5	5	5	4	4	4	3	3
Malta	1	1	1	1	1	1	1	1	1	1	1
Netherlands	5	5	5	5	5	5	5	5	5	5	5
Austria	6	6	6	6	6	6	6	6	6	6	6
Poland	10	10	10	10	10	10	12	12	12	12	13
Portugal	10	10	10	10	18	16	13	13	13	13	14
Romania	9	9	9	9	9	13	11	11	12	11	12
Slovenia	3	3	3	3	3	3	1	1	1	1	1
Slovakia	6	6	5	6	6	6	4	4	4	4	4
Finland	29	29	23	24	23	22	19	18	17	18	19
Sweden	33	32	32	32	33	40	33	31	30	30	32
United Kingdom	55	55	54	55	54	53	45	42	43	42	44
Iceland	14	20	20	20	20	16	1	1	1	7	7
Norway	110	54	54	54	54	54	49	47	47	42	44
Switzerland	7	7	7	7	7	7	6	6	6	6	6
Turkey	41	39	43	47	48	52	48	51	51	50	53

Źródło: opracowanie własne na podstawie danych uzyskanych z strony internetowej:
http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=avia_if_arp&lang=en.

Na podstawie prognoz przedstawionych na rysunku 24 i w tabeli 6 stwierdzono, że prognozowanie zostało wykonane poprawne. Dane przedstawione w tabeli 6 potwierdzają zachowanie wykrytych tendencji danych retrospektywnych w uzyskanych prognozach.

PODSUMOWANIE I WNIOSKI

Cel artykułu został osiągnięty. Wykonano prognozowanie jedną metodą trzydziestu dwóch grup zmiennych. Obserwacja wzrokowa ukazanych prognoz i danych surowych zawarta w tabeli 6 pozwala na stwierdzenie, że prognozowanie zostało przeprowadzone poprawnie. Najwyższa maksymalna wartość prognozy (tabela 6) jest w Francji i wynosi 65, a najniższa – 1. Najniższy poziom występuje w czterech państwach: Luxemburgu, Malcie, Łotwie i Słowenii. Średnia arytmetyczna otrzymanej prognozy to 16,56; a mediana wyniosła 7. Dolny kwartyl wyniósł 4, a górny 33,5. Odchylenie standardowe od średniej arytmetycznej w uzyskanej prognozie wyniosło 18,40.

Ważnym aspektem poruszonym w artykule jest przedstawiona metodyka związana z przekształceniem macierzy w szereg badawczy. Następnie, inną istotną kwestią jest poprawna analiza i ocena danych powstałego szeregu badawczego z wykorzystaniem różnych narzędzi badawczych, których użycie wynika z uzyskanych ocen przeprowadzonych analiz. Ważnym elementem metodyki jest zbudowanie modelu zerojedynkowego oraz jego analiza i ocena. Łączna ocena przeprowadzonych analiz pozwala wybrać metodę do prognozowania na przyszłość. Dodać należy również, że w przypadku wyboru i stosowania do prognozy kilku metod, należy dodatkowo przeprowadzić ich analizę i ocenę stosując wskaźniki w postaci, np. średniego bezwzględnego błędu procentowego.

Uzyskane informacje z przedstawionej metodyki prognozowania jedną metodą trzydziestu dwóch grup zmiennych są niezwykle istotne z punktu planowania na poziomie mikro- i makroekonomicznym. Skuteczne i szybkie prognozowanie wpływa na osiąganie zysków. Opracowywanie coraz to dokładniejszych, szybszych i bardziej zautomatyzowanych metod do prognozowania wynika z zapotrzebowań zgłaszanych przez gospodarkę. Nad metodami do prognozowania należy w dalszym ciągu prowadzić badania, tak aby zaspokoić potrzeby szeroko rozumianej gospodarki.

LITERATURA:

- [1] CIESIELSKI, M., i in., (1999). *Kompendium wiedzy o logistyce*. Poznań: Wydawnictwo Naukowe PWN.
- [2] DITTMANN, P., (2016). *Prognozowanie w przedsiębiorstwie. Metody i ich zastosowanie*. Warszawa: Wolters Kluwer.
- [3] DITTMANN, P., SZABELSKA-PASIERBIŃSKA, E., DITTMANN, I., SZPULAK, A. (2016). *Prognozowanie w zarządzaniu przedsiębiorstwem*. Warszawa: Wolters Kluwer.
- [4] DITTMANN, P., SZABELSKA-PASIERBIŃSKA, E., DITTMANN, I., SZPULAK, A. (2016). *Prognozowanie w zarządzaniu sprzedażą i finansami przedsiębiorstwa*. Warszawa: Wolters Kluwer.
- [5] GRIFFIN, R., (2018). *Podstawy zarządzania organizacjami*, wydanie III. Warszawa: Wydawnictwo Naukowe PWN.

- [6] KOT, S.M., JAKUBOWSKI, J., SOKOŁOWSKI, A. (2011). *Statystyka*. Warszawa: Difin.
- [7] KOZICKI, B., (2018). Metodyka prognozowania zysku. *Systemy Logistyczne Wojsk*, (49), 138–157.
- [8] KOZICKI, B., WAŚCIŃSKI, T., BRZEZIŃSKI, M., LISOWSKA, A. (2018). Cost forecast in a shipping company. *Transport Means*, (1), 1235–1241.
- [9] KOZICKI, B., WAŚCIŃSKI, T., BRZEZIŃSKI, M., TOMASZEWSKI, J. (2018). Zastosowanie prognozy do planowania przychodów przedsiębiorstwa. *Gospodarka Materialowa i Logistyka*, (5), 332–343.
- [10] KOZICKI, B., WAŚCIŃSKI, T., LISOWSKA, A. (2018). Selection of optimal forecasting method for a CPI inflation measure in Poland. W: E. Skrzypek (red.), *Zarządzanie organizacją w warunkach różnorodności* (565–574). Lublin: Katedra Zarządzania Jakością i Wiedzą. Wydział Ekonomiczny. Uniwersytet Marii Curie-Skłodowskiej.

