

**Maciej Oesterreich**Zachodniopomorski Uniwersytet Technologiczny w Szczecinie  
e-mail: moesterreich@zut.edu.pl

---

**SYMULACYJNA ANALIZA WPLYWU LICZBY  
I ROZMIESZCZENIA LUK NIESYSTEMATYCZNYCH  
NA DOKŁADNOŚĆ PROGNOZ**

---

**SIMULATION ANALYSIS OF INFLUENCE OF NUMBER  
AND DISTRIBUTION OF UNSYSTEMATIC GAPS  
ON THE ACCURACY OF FORECASTS**

---

DOI: 10.15611/ekt.2015.2.07

**Streszczenie:** W artykule przeprowadzono statystyczną analizę wpływu rozmieszczenia luk niesystematycznych na poziom błędów prognoz inter- i ekstrapolacyjnych w szeregach czasowych z wahaniami sezonowymi. Zmienna poddana badaniu opisywała kształtowanie się przeciętnego okresu pobytu turystów w obiektach zbiorowego zakwaterowania w województwie zachodniopomorskim w latach 2008-2013 według miesięcy. Charakteryzowała się ona silnymi wahaniami sezonowymi. W obliczeniach wykorzystano metody symulacyjne, które posłużyły do wygenerowania dziesięciu tysięcy układów luk dla trzech wariantów różniących się ich liczbą. Dla wszystkich układów i wariantów oszacowane zostały modele szeregu czasowego z trendem wykładniczym o stałej stopie wzrostu z relatywnie stałą sezonowością. Następnie wyznaczono prognozy inter- i ekstrapolacyjne oraz wyznaczono ich względne błędy. W analizie wykorzystano środowisko obliczeniowe R oraz pakiet Statistica 10.

**Słowa kluczowe:** prognozowanie brakujących danych, metody symulacyjne, analiza rozmieszczenia luk.

**Summary:** In this paper there was conducted a statistical analysis of the impact of the distribution of unsystematic gaps on the accuracy of inter- and extrapolative forecasts in the seasonal time series. In the analysis, as variable, there was used the average period of stay of tourists in accommodation establishments in the West Pomeranian Voivodeship in the years 2008-2013. In calculations there were used simulation methods to generate ten thousand sets of gaps for the three variants, differed in the number of gaps. For all the set and variants of gaps, there were estimated time series models with exponential trend and relatively-fixed seasonality. In the next step there were built inter- and extrapolative forecasts and calculated their relative errors (MAPE). In the analysis there were used R program and Statistica 10.

**Keywords:** forecasting of missing data, simulation methods, analysis of gaps distribution.

## 1. Wstęp

W pracach dotyczących prognozowania brakujących danych w szeregach czasowych z wahaniami sezonowymi analizie poddanych zostało ok. 30 zmiennych o różnym natężeniu sezonowości. Dla każdej z nich rozpatrywano nie więcej niż kilkanaście wariantów luk (por. np. [Zawadzki 1999; 2003; 2006; 2012]). W tej sytuacji możliwość uogólnienia wyników o wpływie rozmieszczenia i liczby luk na poziom błędów prognoz na dowolne zmienne i dowolne układy luk, budzi poważne wątpliwości. Można stwierdzić, że błędy dla określonych układów luk są co najwyżej niższe niż dla innego.

Celem niniejszego artykułu było zastosowanie metod symulacyjnych do badania wpływu rozmieszczenia i rozkładu luk niesystematycznych na poziom błędów prognoz inter- i ekstrapolacyjnych.

Wykorzystanie metod symulacyjnych polegało na wygenerowaniu dla każdego z trzech wariantów, różniących się liczbą (odsetkiem) luk, po dziesięć tysięcy kombinacji (układów) luk. Dane te posłużyły następnie do oszacowania modeli i wyznaczenia prognoz inter- i ekstrapolacyjnych oraz obliczenia ich średnich względnych błędów (zob. [Oesterreich 2012]).

Do budowy prognoz zostały wykorzystane predyktory oparte na klasycznym modelu szeregu czasowego, w którym sezonowość została opisana za pomocą wielomianu trygonometrycznego [Zeliaś, Pawełek, Wanat 2008, s. 89-90]. Obliczenia wykonano z wykorzystaniem pakietu R.


## 2. Charakterystyka zmiennej prognozowanej

Modelowaniu i prognozowaniu poddano średni okres pobytu turystów w obiektach zbiorowego zakwaterowania w województwie zachodniopomorskim w latach 2008-2013 według miesięcy. Wartości zmiennej były ilorazami dwóch innych zmiennych – liczby udzielonych noclegów w obiektach zbiorowego zakwaterowania oraz liczby turystów. Dane statystyczne zaczerpnięto z ukazujących się w cyklu rocznym opracowań GUS pt.: „Turystyka”. Dane z lat 2008-2012 posłużyły do budowy modeli natomiast rok 2013 był okresem empirycznej weryfikacji prognoz. Kształtowanie się zmiennej prognozowanej przedstawiono na rys. 1.

Z rysunku wynika, że zmienna charakteryzowała się silnymi wahaniami sezonowymi o malejącej amplitudzie oraz niewielkiej tendencji spadkowej. Z rysunku w skali półlogarytmicznej wynika, że wahania te są relatywnie stałe.

W tabeli 1 zostały zestawione oceny wskaźników sezonowości.

Jak wynika z tab. 1, zmienna charakteryzuje się występowaniem wyraźnych minimum i maksimum sezonowych. Zjawisko to związane jest ze specyfiką ruchu turystycznego w województwie zachodniopomorskim, silnie powiązaną z temperaturą powietrza oraz porami roku. Minima sezonowe przypadają na miesiące zimowe: sty-



**Rys. 1.** Kształtowanie się przeciętnego okresu pobytu turystów w obiektach zbiorowego zakwaterowania w województwie zachodniopomorskim według miesięcy

Źródło: opracowanie własne na podstawie: „Turystyka” za lata 2008-2013.

**Tabela 1.** Kształtowanie się ocen wskaźników sezonowości według miesięcy (w %)

Miesiące	I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII
Wskaźniki sezonowości	81,9	94,0	95,1	91,9	98,1	111,7	124,9	121,9	107,8	93,9	91,0	87,9

Źródło: opracowanie własne.

czeń (81,9%) oraz grudzień (87,9%). Natomiast maksima występują w miesiącach letnich: lipcu (124,9%) oraz sierpniu (121,9%). Różnica między maksymalną a minimalną oceną wskaźników sezonowości wynosząca 43 punkty procentowe (p.p.) świadczy o silnym ich natężeniu.

### 3. Przebieg badania

W pierwszym etapie analizy, korzystając z pakietu statystycznego R, wylosowano po dziesięć tysięcy układów luk niesystematycznych dla trzech wariantów zawierających odpowiednio:

- W1 – 5 luk (8,3% długości okresu „próby”),
- W2 – 10 luk (16,7% długości okresu „próby”),
- W3 – 15 luk (25% długości okresu „próby”).

Następnie na podstawie dostępnych danych oszacowano parametry modeli, zbudowano prognozy oraz obliczono ich średnie względne błędy (MAPE). Do budowy prognoz inter- i ekstrapolacyjnych wykorzystano klasyczne predyktory oparte na modelach szeregu czasowego z trendem wykładniczym oraz z relatywnie stałą sezonowością:

$$\ln Y_t = \alpha_0 + \alpha_1 t + \sum_{i=1}^6 (a_{ji} \sin \omega_i t + b_{ji} \cos \omega_i t) + \varepsilon_t, \quad (1)$$

gdzie:

$$\omega = \frac{2\pi \cdot i}{m} \quad (2)$$

$t = 1, 2, \dots, 60$ ;  $i = 1, 2, \dots, 6$ ;  $m = 12$ .

W wyniku obliczeń uzyskano sześć szeregów (po dwa dla każdego wariantu) zawierających dziesięć tysięcy średnich względnych błędów prognoz (MAPE).

Następnie zbudowano macierz zawierającą informację o liczbie luk w poszczególnych miesiącach.

#### 4. Wyniki badań

W tabeli 2 zestawiono informację o minimalnych, maksymalnych i przeciętnych ocenach oraz współczynnikach zmienności średnich względnych błędów prognoz (MAPE) inter- i ekstrapolacyjnych dla wariantów W1-W3.

**Tabela 2.** Minimalne, maksymalne i przeciętne oceny oraz współczynniki zmienności błędów prognoz (MAPE) inter- i ekstrapolacyjnych według wariantów luk (w %)

Wariant	Prognozy interpolacyjne				Prognozy ekstrapolacyjne			
	min	max	$\bar{x}$	$V_s$	min	max	$\bar{x}$	$V_s$
W1	0,68	9,98	3,75	35,16	3,27	5,88	4,53	7,78
W2	1,34	8,42	3,86	24,21	2,86	6,61	4,57	11,20
W3	1,44	7,66	3,95	18,42	2,74	7,16	4,63	13,68

Źródło: opracowanie własne.

Z informacji zawartych w tabeli wynika, że wraz ze wzrostem liczby (odsetka) luk rosły nieznacznie błędy względne obu rodzajów prognoz. Dla prognoz interpolacyjnych różnica ocen między wariantami W3 i W1 wynosiła 0,2 p.p., a ekstrapolacyjnych 0,1 p.p. Odmiennie kształtowały się relacje współczynników zmienności – dla prognoz interpolacyjnych wykazywały one tendencję malejącą, a dla ekstrapolacyjnych rosnącą. Dla prognoz interpolacyjnych, wraz ze wzrostem liczby (odsetka) luk, malała różnica pomiędzy skrajnymi ocenami błędów – z 9,30 p.p. (wariant W1) do 6,22 p.p. (wariant W3). Dla prognoz ekstrapolacyjnych oceny te wzrastały z 2,41 p.p. dla wariantu W1 do 4,42 p.p. dla wariantu W3.

Niewielkie zróżnicowanie przeciętnych ocen względnych błędów prognoz nie pozwalało na zbadanie wpływu układów luk na dokładność prognoz. Z wcześniejszych badań wynika, że przeciętnie wyższymi ocenami błędów charakteryzują się

prognozy w podokresach, w których przypadają minima sezonowe (zob. [Oesterreich 2014]). Dla dziesięciu tysięcy prognoz przeprowadzanie badań tego rodzaju nie było możliwe, ponieważ rozkład udziałów poszczególnych miesięcy był jednostajny.

Dlatego, w celu zbadania wpływu rozmieszczenia luk na dokładność prognoz, dla każdego wariantu, z szeregu zawierającego po dziesięć tysięcy ocen błędów (MAPE) obu rodzaju prognoz, wyodrębniono pierwszy (P\_01) i ostatni (P\_99) percentyl. Do pierwszego percentyla należało sto układów luk charakteryzujących się najniższymi ocenami błędów prognoz, natomiast do ostatniego najwyższymi. Informację o minimalnych, maksymalnych i przeciętnych poziomach błędów prognoz oraz ich współczynnikach zmienności dla wariantów W1-W3 przedstawiono w tab. 3.

**Tabela 3.** Minimalne, maksymalne i przeciętne oceny oraz współczynniki zmienności błędów prognoz (MAPE) inter- i ekstrapolacyjnych dla pierwszego i ostatniego percentyla według wariantów luk (w %)

Wariant	W1				W2				W3			
	Błąd	min	max	$\bar{x}$	$V_s$	min	max	$\bar{x}$	$V_s$	min	max	$\bar{x}$
Prognozy interpolacyjne												
P_01	0,68	1,33	1,16	12,55	1,34	1,94	1,75	8,04	1,44	2,37	2,19	7,01
P_99	7,18	9,98	7,75	6,69	6,12	8,42	6,58	7,29	5,76	7,66	6,30	8,08
Prognozy ekstrapolacyjne												
P_01	3,27	3,58	3,49	1,89	2,86	3,42	3,29	3,40	2,74	3,33	3,20	3,78
P_99	5,31	5,88	5,46	2,56	5,77	6,61	5,95	2,63	6,16	7,16	6,37	3,17

Źródło: opracowanie własne.

Charakterystyki ocen błędów dotyczących skrajnych percentyli, w takim samym układzie jak w tab. 2, zestawione zostały w tab. 3. Z tabeli wynika, że zarówno oceny współczynników zmienności, jak i oceny rozstępu uległy znacznemu zmniejszeniu. W przypadku prognoz interpolacyjnych dla percentyla P\_01 przeciętne względne błędy wykazywały tendencję rosnącą – od 1,16% dla wariantu W1 do 2,19% dla wariantu W3. Odmienną tendencję można zaobserwować dla percentyla P\_99 (od 7,75% dla wariantu W1 do 6,30% dla wariantu W3). Relacje przeciętnych błędów prognoz ekstrapolacyjnych były analogiczne. Dla percentyla P\_01 różnice skrajnych ocen wynosiły 0,29 p.p. dla P\_99 0,91 p.p.

Dla prognoz interpolacyjnych, trzech wariantów luk oraz percentyli P\_01 i P\_99 zbadano częstości występowania luk w poszczególnych miesiącach. Informacje te przedstawiano w tab. 4.


Z analizy danych zawartych w tab. 4 wynika, że najniższe oceny błędów prognoz interpolacyjnych (percentyl P\_01) otrzymano dla układów, w których luki występowały przede wszystkim: w lutym, marcu, maju, sierpniu, listopadzie i grudniu. Odsetki luk w tych miesiącach wykazywały, poza sierpniem, tendencję malejącą

**Tabela 4.** Udziały luk w miesiącach dla pierwszego oraz ostatniego percentyla ocen błędów prognoz (MAPE) interpolacyjnych według wariantów (w %)

Wariant luk	Percentyl	Miesiąc											
		I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII
W1	P_01	1,4	10,2	10,6	4,8	17,2	4,2	7,2	8,0	6,8	4,8	14,2	10,6
	P_99	18,6	4,6	4,0	6,0	7,4	11,0	23,8	2,6	5,8	10,8	3,0	2,4
W2	P_01	3,9	10,3	10,5	8,3	10,9	6,1	6,2	8,9	6,3	4,7	11,9	12,0
	P_99	14,3	5,0	6,9	6,0	8,4	7,8	17,3	7,5	6,6	10,9	4,3	5,0
W3	P_01	4,8	9,9	9,7	8,3	9,3	6,9	6,5	9,7	7,7	6,8	10,7	9,5
	P_99	10,6	5,9	6,6	7,6	8,9	8,6	16,9	6,2	7,7	9,3	6,2	5,7

Źródło: opracowanie własne.


wraz ze wzrostem liczby luk. Różnice między wariantami W1 i W3 wynosiły dla: marca – 0,9 p.p., maja – 7,9 p.p., listopada – 3,5 p.p. Na rysunku 2 zestawiono informację o udziałach luk dla pierwszego percentyla prognoz interpolacyjnych według miesięcy.

**Rys. 2.** Udziały luk w miesiącach dla pierwszego percentyla błędów prognoz (MAPE) interpolacyjnych według wariantów luk

Źródło: opracowanie własne.

W układach luk dla ostatniego percentyla najwyższe odsetki błędów prognoz interpolacyjnych przypadają na: styczeń, lipiec oraz październik. Dla wariantu W1 udziały luk w tych miesiącach wynosiły odpowiednio: 18,6, 23,8 oraz 10,8%. Kierunki zmian częstości luk, spowodowane zwiększaniem się ich liczby, były zgodne z kierunkiem zmian dla pierwszego percentyla.

Na rysunku 3 zestawiono informację o udziałach luk w ostatnim percentylu prognoz interpolacyjnych według miesięcy.



**Rys. 3.** Udziały luk w miesiącach dla ostatniego percentyla błędów prognoz (MAPE) interpolacyjnych według wariantów luk

Źródło: opracowanie własne.

W tabeli 5 zestawiono oceny współczynników korelacji liniowej pomiędzy liczbami luk dla pierwszego i ostatniego percentyla prognoz interpolacyjnych.

**Tabela 5.** Oceny współczynników korelacji liniowej Pearsona pomiędzy liczbami luk w pierwszym i ostatnim percentylu według wariantów luk dla prognoz interpolacyjnych

Wariant	Percentyl	W1		W2		W3	
		P01	P99	P01	P99	P01	P99
W1	P_01	1,00	-0,49	0,85	-0,45	0,80	-0,31
	P_99	-0,49	1,00	-0,72	0,95	-0,84	0,95
W2	P_01	0,85	-0,72	1,00	-0,70	0,93	-0,59
	P_99	-0,45	0,95	-0,70	1,00	-0,79	0,93
W3	P_01	0,80	-0,84	0,93	-0,79	1,00	-0,69
	P_99	-0,31	0,95	-0,59	0,93	-0,69	1,00

Źródło: opracowanie własne.

Analiza współczynników korelacji liniowej potwierdziła istnienie silnej, dodatniej zależności pomiędzy liczbą luk zarówno w pierwszych, jak i ostatnich percentylach błędów prognoz dla różnych wariantów luk. Jednocześnie oceny współczynników pomiędzy skrajnymi percentylami w ramach poszczególnych wariantów

wskazują na ujemną, umiarkowaną (wariant W1) lub silną (wariant W2 i W3) zależność.

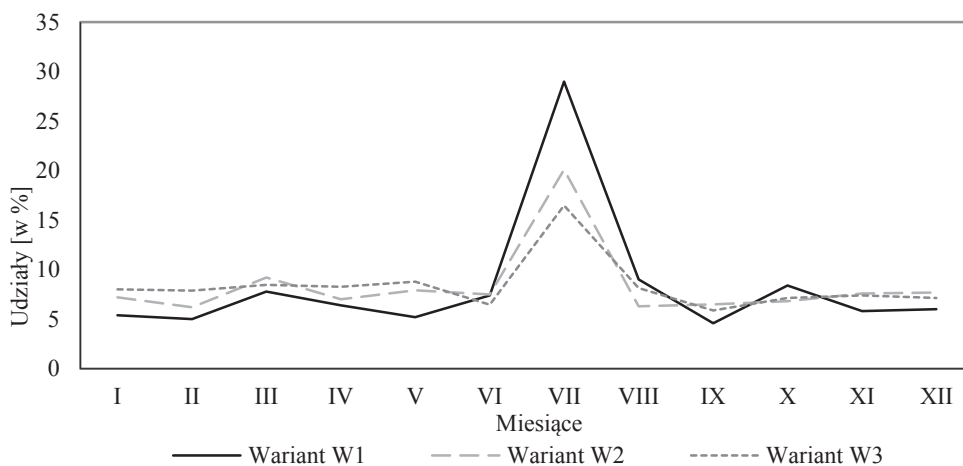
Oceny te dość znacznie odbiegają od  $-1$ , co oznacza, że na wysokość błędów prognoz interpolacyjnych mogą wpływać również inne czynniki, takie jak np. sekwencyjność luk.

W tabeli 6 zestawiono informację o udziale luk w poszczególnych miesiącach dla pierwszego i ostatniego percentyla błędów (MAPE) prognoz ekstrapolacyjnych według wariantów luk.

**Tabela 6.** Udziały luk w poszczególnych miesiącach i dla pierwszego oraz ostatniego percentyla ocen błędów prognoz (MAPE) ekstrapolacyjnych według wariantów (w %)

Wariant luk	Percentyl	Miesiąc											
		I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII
W1	P_01	5,4	5,0	7,8	6,4	5,2	7,4	29,0	9,0	4,6	8,4	5,8	6,0
	P_99	11,4	9,0	4,8	8,2	13,0	9,0	2,4	1,8	9,2	15,4	3,6	12,2
W2	P_01	7,2	6,2	9,2	7,0	7,9	7,5	20,1	6,3	6,5	6,8	7,6	7,7
	P_99	10,5	9,9	6,1	8,7	11,4	9,0	3,7	5,9	6,2	13,7	6,0	8,9
W3	P_01	8,0	7,9	8,5	8,3	8,8	6,5	16,5	8,1	5,9	7,1	7,4	7,1
	P_99	10,7	9,3	7,3	7,5	11,7	7,9	4,8	5,0	7,5	11,7	7,1	9,5

Źródło: opracowanie własne.



**Rys. 4.** Udziały luk w miesiącach dla pierwszego percentyla błędów prognoz (MAPE) ekstrapolacyjnych według wariantów luk

Źródło: opracowanie własne.



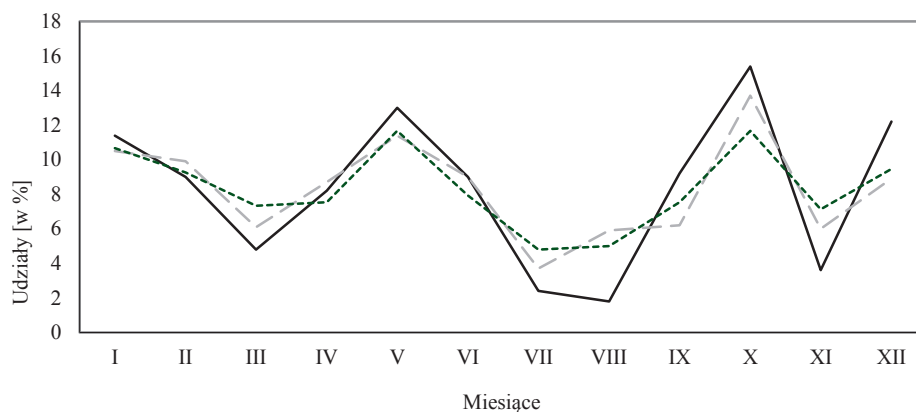
Najwyższe udziały luk dla pierwszego percentyla błędów (MAPE) prognoz ekstrapolacyjnych występowały przede wszystkim w lipcu. Wynosiły one, dla wariantów W1-W3, odpowiednio: 29, 20,1, 16,5%. Udziały luk w pozostałych miesiącach były wyraźnie niższe i nie przekraczały dla: W1 – 9%, W2 – 9,2%, W3 – 8,8%.

Na rysunku 4 przedstawiono w formie graficznej informację o udziałach luk w pierwszym percentylu prognoz ekstrapolacyjnych według miesięcy.

Dla prognoz ekstrapolacyjnych o najwyższych ocenach błędów (P<sub>99</sub>) luki występowały najczęściej w: styczniu, maju, październiku i grudniu. Dla wariantu W1 udziały luk w tych miesiącach wynosiły odpowiednio: 11,4, 13, 15,4, i 12,2%. Wraz ze wzrostem liczby luk odsetki te wykazywały tendencję malejącą i dla wariantu W3 zmniejszyły się odpowiednio do: 10,7, 11,7, 11,7 i 9,5%.

Najniższe odsetki luk dla ostatniego percentyla błędów prognoz ekstrapolacyjnych przypadają na marzec, lipiec, sierpień oraz listopad.

Na rysunku 5 przedstawiono graficznie udziały luk dla P<sub>99</sub> prognoz ekstrapolacyjnych według miesięcy.



**Rys. 5.** Udziały luk w miesiącach dla ostatniego percentyla błędów prognoz (MAPE) ekstrapolacyjnych według wariantów luk

Źródło: opracowanie własne.

W tabeli 7 zestawiono oceny współczynników korelacji liniowej Pearsona pomiędzy liczbami luk dla pierwszego i ostatniego percentyla według wariantów luk dla prognoz ekstrapolacyjnych.

Analiza współczynników korelacji liniowej, podobnie jak w ramach prognoz interpolacyjnych, potwierdziła istnienie bardzo silnej dodatniej zależności pomiędzy liczbą luk, zarówno dla pierwszych, jak i ostatnich percentyli. Jednocześnie oceny współczynników pomiędzy skrajnymi percentylami w ramach poszczególnych wariantów wskazują na ujemną, umiarkowaną zależność w tym względzie. Oznacza to istnienie różnic w udziałach dla poszczególnych miesięcy między percentylami: pierwszym i ostatnim.

**Tabela 7.** Oceny współczynników korelacji liniowej Pearsona pomiędzy liczbami luk w pierwszym i ostatnim percentylu według wariantów luk dla prognoz interpolacyjnych

Wariant	Percentyl	W1		W2		W3	
		P01	P99	P01	P99	P01	P99
W1	P_01	1,00	-0,47	0,96	-0,51	0,94	-0,54
	P_99	-0,47	1,00	-0,43	0,90	-0,45	0,93
W2	P_01	0,96	-0,43	1,00	-0,53	0,95	-0,46
	P_99	-0,51	0,90	-0,53	1,00	-0,46	0,93
W3	P_01	0,94	-0,45	0,95	-0,46	1,00	-0,43
	P_99	-0,54	0,93	-0,46	0,93	-0,43	1,00

Źródło: opracowanie własne.

W tabeli 8 zestawione zostały, dla wariantów W1-W3, oceny współczynników korelacji liniowej Pearsona pomiędzy ocenami wskaźników sezonowości a udziałami luk w poszczególnych miesiącach dla pierwszego i ostatniego percentyla błędów obu rodzajów prognoz.

**Tabela 8.** Współczynniki korelacji liniowej Pearsona pomiędzy udziałami luk w poszczególnych miesiącach a ocenami wskaźników sezonowości według wariantów luk

Percentyl	Wariant		
	W1	W2	W3
Prognozy interpolacyjne			
P_01	-0,060	-0,199	-0,059
P_99	0,252	0,311	0,425
Prognozy ekstrapolacyjne			
P_01	0,641	0,509	0,484
P_99	-0,572	-0,573	-0,699

Źródło: opracowanie własne.

Z informacji zawartych w tabeli wynika, że dla pierwszego percentyla prognoz interpolacyjnych istniała bardzo słaba, ujemna zależność między częstościami luk a ocenami wskaźników sezonowości. Natomiast dla ostatniego percentyla oceny te były dodatnie i wykazywały tendencję rosnącą. Oceny współczynników korelacji wzrosły z 0,252 dla wariantu W1 do 0,425 dla wariantu W3.

W przypadku prognoz ekstrapolacyjnych bezwzględne poziomy ocen współczynników korelacji liniowej były wyższe od odpowiednich ocen dla prognoz interpolacyjnych. Dla percentyla P\_01 były one dodatnie i wykazywały tendencję spadkową z 0,641 (W1) do 0,484 (W3). Natomiast dla percentyla ostatniego przyjęły one wartości ujemne i zwarte były w przedziale od -0,699 (W3) do -0,572 (W1).

## 5. Podsumowanie

Z przeprowadzonych w artykule analiz można wysunąć następujące wnioski:

1. Przeciętne oceny względnych błędów prognoz wzrastały w miarę wzrostu liczby (odsetka) luk.
2. W ramach prognoz interpolacyjnych malały różnice między skrajnymi ocenami błędów. Dla prognoz ekstrapolacyjnych miała miejsce tendencja odwrotna.
3. W celu zbadania wpływu rozmieszczenia luk na dokładność prognoz z dziesięciu tysięcy układów wybrano po sto o najniższych i najwyższych ocenach błędów oraz porównano częstości występowania luk w poszczególnych miesiącach.
4. Z przeprowadzonych dla wariantów W1-W3 analiz porównawczych wynika, że występuje zgodność częstości dla tych samych percentyli i rodzaju prognoz.
5. Zasadniczo różnią się natomiast częstości między skrajnymi percentylami.
6. Z analiz współczynników korelacji pomiędzy częstościami występowania luk i wskaźnikami sezonowości wynika, że dla prognoz interpolacyjnych występuje słaba dodatnia zależność dla ostatniego percentyla. Dla prognoz ekstrapolacyjnych jest ona umiarkowana, ale różna co do kierunku. Dla pierwszego percentyla była ona dodatnia, a dla ostatniego ujemna.

Uzyskane wyniki mogą stać się podstawą do dalszych badań mających na celu poprawę dokładności prognoz inter- i ekstrapolacyjnych wyznaczonych na podstawie niekompletnych szeregów czasowych wykazujących wahania sezonowe.

## Literatura

- Oesterreich M., 2012, *Symulacyjne badanie wpływu częstości występowania luk niesystematycznych na dokładność prognoz*, Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu, seria: Ekonomia 4(38), Wrocław.
- Oesterreich M., 2014, *Badanie wpływu częstości występowania luk systematycznych w mikroekonomicznym szeregu czasowym na dokładność prognoz*, [w:] *Problemy społeczno-ekonomiczne w relacjach międzynarodowych: analiza modelowa rozwoju regionów*, Wydawnictwo Uniwersytetu Ekonomicznego w Katowicach, Katowice.
- Zawadzki J. (red), 1999, *Ekometryczne metody predykcji dla danych sezonowych w warunkach braku pełnej informacji*, Wydawnictwo Uniwersytetu Szczecińskiego, Szczecin.
- Zawadzki J., 2012, *Z badań nad metodami prognozowania na podstawie niekompletnych szeregów czasowych z wahaniami okresowymi (sezonowymi)*, Przegląd Statystyczny – numer specjalny 1, Warszawa.
- Zawadzki J. (red.), 2003, *Zastosowanie hierarchicznych modeli szeregów czasowych w prognozowaniu zmiennych ekonomicznych z wahaniami sezonowymi*, Wydawnictwo Akademii Rolniczej w Szczecinie, Szczecin.
- Zawadzki J., 2006, *Zastosowanie nieklasycznej metody prognozowania brakujących danych sezonowych (na przykładzie produkcji masła)*, Acta Agraria et Silvestria: Series Agraria. vol. 47, Kraków.
- Zeliaś A., Pawełek B., Wanat S., 2003, *Prognozowanie ekonomiczne. Teoria, przykłady, zadania*, PWN, Warszawa.