

## PROGNOZOWANIE PRZYCHODÓW CAŁKOWITYCH W JIT NA ROK 2020

## FORECASTING OF TOTAL REVENUES IN THE JIT FOR 2020

**Bartosz KOZICKI**

bartosz.kozicki@wat.edu.pl

<https://orcid.org/0000-0001-6089-952X>

Wojskowa Akademia Techniczna

Wydział Bezpieczeństwa, Logistyki i Zarządzania

Instytut Logistyki

**Łukasz ĆWIEKOWSKI**

cwiek96@wp.pl

**Artur KOSZAREK**

artur1201@wp.pl

<https://orcid.org/0000-0002-6426-0587>

Inspektorat Wsparcia Sił Zbrojnych

**Streszczenie:** W artykule został sformułowany problem badawczy dotyczący analizy, oceny i prognozowania przychodów całkowitych przedsiębiorstw JIT (Logistic Just in Time) w ujęciu miesięcznym na rok 2020. Przeprowadzono analizę literatury przedmiotu badań dotyczącą przychodów oraz prognozowania. Badania rozpoczęto od narysowania wykresu liniowego danych pierwotnych. Oceną obserwacji wzrokowej było zaobserwowanie tendencji w postaci trendu i sezonowości. Użytymi w artykule narzędziami badawczymi potwierdzono istnienie prawidłowości w rozpatrywanych danych retrospektywnych. Krytyczna analiza literatury dotyczącej prognozowania pozwoliła na wybór metody wygładzania wykładniczego Holta-Wintersa do prognozowania danych pierwotnych na przyszłość. Uzyskane prognozy zostały podane analizie i ocenie.

**Abstract:** The article presents a research problem concerning the analysis, evaluation and forecasting of total revenues of JIT (Logistic Just in Time) enterprises in monthly terms for 2020. An analysis of the literature on the subject of revenues and forecasting was conducted. The study began with creating a line graph of primary data. Regularities in the form of trends and seasonality were the evaluation of visual observation. The research tools used in the article confirmed the existence of regularities in the retrospective data under consideration. Critical analysis of the literature related to forecasting has enabled the selection of the Holt-Winter's exponential smoothing method for the forecasting of primary data for the future. The obtained forecasts were analyzed and evaluated.

**Słowa kluczowe:** przychody, prognozowanie

**Keywords:** revenues, forecasting

## WSTĘP

W artykule podjęto próbę przeprowadzenia analizy, oceny i prognozowania przychodów całkowitych w ujęciu dynamicznym.

Podmiotem badań jest przedsiębiorstwo logistyczne JIT (Logistic Just in Time) Sp. z o.o. z siedzibą w Warszawie, które zostało założone w sierpniu 2014 r. i świadczy usługi transportowo-spedycyjno-logistyczne. Obszarem funkcjonowania podmiotu badań jest rynek krajowy i międzynarodowy. W podmiocie badań zatrudnionych jest 18 osób: 10 spedytorów (w tym kierownik spedycji), 3 pracowników administracji (w tym kierownik administracji), 3 pracowników księgowości (w tym główna księgowa) oraz 2 członków zarządu. Przedsiębiorstwo zajmuje się świadczeniem usług transportowych na terenie całej Europy, autami dostawczymi o dopuszczalnej masie całkowitej do 3,5 t.auta dostawcze wraz z kierowcami, którymi się posługuje podmiot badań, należą do stałych podwykonawców. Podmiot badań wykorzystuje 42 auta dostawcze należące do 16 podwykonawców.

**Przedmiotem badań** niniejszej pracy będą przychody całkowite osiągnięte przez podmiot badań w latach 2015-2019.

**Problem badawczy** artykułu koncentruje się wokół analizy, oceny i prognozowania danych pierwotnych dotyczących przychodów całkowitych w badanym podmiocie.

**Celem artykułu** jest przeprowadzenie analizy i oceny danych retrospektywnych przychodów zaewidencjonowanych w podmiocie badań, a na ich podstawie wykonanie prognozowania na przyszłość.

Dla tak przyjętego problemu badawczego i celu pracy sformułowano **główne pytanie badawcze**, które brzmi w sposób następujący:

Czy przeprowadzenie analizy i oceny przychodów całkowitych w latach 2015-2019 pozwoli wykonać ich prognozowanie na przyszłość?

Artykuł składa się ze wstępu, 5 punktów merytorycznych, podsumowania i wniosków.

## 1. ANALIZA LITERATURY PRZEDMIOTU BADAŃ

Istotą funkcjonowania przedsiębiorstwa jest osiągnięcie zysków przez efektywne wykorzystanie posiadanych zasobów. Poprawne zarządzanie posiadanymi zasobami pozwala realizować założone cele. Zasoby przedsiębiorstw są ograniczone (Hofer, Eisl, Mayr, 2015). W procesie planowania należy rozpatrywać różne warianty ich wykorzystania, pod kątem wyboru optymalnego. „Granicami” w podejmowaniu decyzji są informacje dotyczące kosztów i przychodów (Box, Jenkins, Reinsel, Ljung, 2015; Du, Leung, Zhang, Lai, 2013). Istotnym aspektem funkcjonowania przedsiębiorstwa jest dysponowanie aktualnymi, wiarygodnymi informacjami. Przedsiębiorstwo jest elementem gospodarki, na którą oddziałuje otoczenie. Musi funkcjonować w sposób

elastyczny tak, aby właściwie realizować przyjęte cele przy oddziaływaniu czynników losowych (Hastie, Tibshirani, Friedman, 2009).

Pierwszą i elementarną funkcją zarządzania jest planowanie. Oprócz planowania do funkcji zarządzania Ricky W. Griffin zalicza: organizowanie, przewodzenie i kontrolowanie (Griffin, 2000, s. 179). Funkcje zarządzania wykorzystują do realizacji przyjętych celów posiadane zasoby w postaci:

- zasobów ludzkich, czyli kadry kierowniczej i siły roboczej;
- zasobów finansowych, w skład których wchodzi kapitał finansowy, potrzebny do finansowania bieżącego oraz długofalowego działania firmy;
- zasobów rzeczowych – definiowanych jako ogół pomieszczeń zarówno produkcyjnych, jak i biurowych, a także urządzenia, materiały;
- zasobów informacyjnych, czyli dwie dane lub więcej umożliwiające podejmowanie decyzji w zarządzaniu przedsiębiorstwem.

Krytyczna analiza literatury pozwala na stwierdzenie, że termin „planowanie” jest przez badaczy różnie interpretowany. Planowanie opiera się na przewidywaniu, podczas którego określa się wybór danych wariantów działań. Celem planowania jest realizacja przyjętych w planach celów przez podejmowanie decyzji, które są zorientowane na przyszłość, racjonalne, nastawione na podjęcie działań. Hans Ulrich wyodrębnił siedem ujęć planowania w postaci: klasycznej ekonomiki przedsiębiorstwa; decyzyjnie zorientowanej; podejścia informacyjnego, matematycznego, behawioralnego, systemowego, filozoficznego (Krupski, 2014, s. 47-48; Maia, De Carvalho, 2011).

Celem planowania jest bilansowanie się zaplanowanych potrzeb z przeznaczonymi na ich zabezpieczenie środkami. Dobrze dobrany plan przez skuteczne zarządzanie posiadanymi zasobami może pozwolić na realizację założonych celów. W planowaniu olbrzymią rolę odgrywa prognozowanie.

Proces prognozowania rozpoczyna się od analizy i oceny danych z przeszłości. Na tej podstawie dobiera się metody do prognozowania na przyszłość. Prognozowanie jest racjonalnym, naukowym przewidywaniem przyszłych zdarzeń (Dittmann, Szabela-Pasierbińska, Dittmann, Szpulak, 2016, s. 22-36).

Wynikiem prognozowania jest prognoza. Prognoza jest sądem dotyczącym stanu zjawiska w danym momencie w przyszłości. Jej racjonalność wynika z odnoszenia się do nauki, która prowadzi od przesłanek do gotowych wniosków. Niezwykle ważne jest precyzyjne formułowanie prognozy w sposób umożliwiający empiryczną weryfikowalność. Sporządzając prognozy, musimy mieć świadomość, że często są one nietrafione, jednak ważne jest ich sporządzanie, ze względu na redukcję wystąpienia ryzyka, które wiąże się z decyzjami podjętymi przez podmiot gospodarczy. Dlatego też prognozy określa się jako trafne w przypadku, gdy są zbliżone do wielkości prognozowanych, lub nietrafione w momencie dużych różnic między danymi prognozowanymi a rzeczywistymi. Uznając prognozę za dopuszczalną – czyli taką,

która jest akceptowalna – należy ustalić, w jakim stopniu występuje niepewność (Holt, 2004; Wang, Chen, 2019).

Podstawowe funkcje prognoz są następujące:

- informacyjna – jej zadaniem jest dostarczenie informacji na temat badanego zjawiska,
- preparacyjna – służy przy podejmowaniu słusznych decyzji przez generowanie dodatkowych motywów,
- aktywizująca – jest motywem działań, które sprzyjają podczas tworzenia korzystnej prognozy.

Wskutek krytycznej analizy literatury zaobserwowano, że najczęściej stosowany jest podział metod prognozowania na ilościowe i jakościowe.

Metody ilościowe oparte są na formalnych modelach prognostycznych zbudowanych na podstawie danych dotyczących kształtowania się wartości zmiennej prognozowanej i zmiennych objaśniających w przeszłości. Należą do nich modele szeregów czasowych, ekonometryczne, analogowe, ze zmiennymi wiodącymi, analizy kohortowej, testy rynkowe (Dittmann, 2003, s. 36).

W metodzie jakościowej wyniki prognozy wyrażane są słownie. Spodziewane efekty tej metody możemy zaobserwować wówczas, gdy strategia przedsiębiorstwa, jak również jego otoczenia pozostaje niezmienna lub zmienia się w niewielkim stopniu.

Metody jakościowe oparte są na sądach pojedynczych ekspertów lub grup ekspertów, które mogą (lecz nie muszą) być formułowane na podstawie danych dotyczących kształtowania się wartości zmiennej prognozowanej i zmiennych objaśniających w przeszłości (Dittmann, 2003, s. 36). Dotyczą one zmiennej niemierzalnej. Należą do niej metody wynikające z opinii sprzedawców, kierownictwa, ekspertów, a także badania intencji nabywców. Zaletą tej metody jest szybsze zaimplementowanie efektów zmian zaistniałych w strategii przedsiębiorstwa lub jego otoczenia przez wykorzystanie opinii osób obserwujących te zmiany.

Krytyczna analiza literatury pozwala na stwierdzenie, że w przedsiębiorstwach często dokonuje się prognozowania przychodów. Przychody w ujęciu ekonomicznym oznaczają sumę otrzymanych lub należnych środków pieniężnych w zamian za wykonanie i dostarczenie na rzecz kontrahentów świadczenia w postaci produktów, towarów, materiałów i usług (Gabrusewicz, 2014, s. 183).


Do powstania przychodów niezbędny jest zatem rynek, na którym odbywają się transakcje kupna i sprzedaży, jak również kupujący i sprzedający (Srivastava, Agarwal, Garg, Patni, 2016). Zgodnie z ustawą o rachunkowości przychody obejmują przychody ze sprzedaży dóbr, świadczenia usług oraz z tytułu użytkowania aktywów jednostki przez inne podmioty.

Następnym etapem badań będzie przeprowadzenie wielowymiarowej analizy danych pierwotnych pozyskanych z podmiotu badań.

## 2. ANALIZA I OCENA DANYCH PIERWOTNYCH

Analizę danych pierwotnych przeprowadzono, stosując dostępne narzędzia badawcze. Zastosowanie narzędzi badawczych do analiz danych pierwotnych pozwoliło na dokonanie ich oceny. Oceną przeprowadzonych analiz będzie wykrycie prawidłowości w obserwowanych zjawiskach masowych.

Badania rozpoczęto od nakreślenia wykresu liniowego danych pierwotnych w postaci przychodów całkowitych w ujęciu miesięcznym w latach 2015-2019 (rys. 1).




Rys. 1. Wykres liniowy przychodów całkowitych w ujęciu miesięcznym w latach 2015-2019

Źródło: Opracowanie własne

Z przeprowadzonej obserwacji wzrokowej informacji zawartych na rysunku 1 wynika, że w obserwowanych danych retrospektywnych istnieje zjawisko trendu i sezonowości w ujęciu miesięcznym.


Następnie postanowiono zbadać rozkład analizowanych danych pierwotnych. Do realizacji tego celu użyto narzędzi badawczych w postaci: histogramu (rys. 2) i wykresu normalności (rys. 3).



Rys. 2. Histogram przychodów całkowitych w ujęciu miesięcznym w latach 2015-2019

Źródło: Opracowanie własne


Oceną informacji zawartych na rysunku 2 jest jednoznaczne stwierdzenie, że rozkład rozpatrywanych danych dotyczących przychodów całkowitych podmiotu badań w ujęciu miesięcznym w latach 2015-2019 nie jest normalny.



Rys. 3. Wykres normalności przychodów całkowitych w ujęciu miesięcznym w latach 2015-2019  
Źródło: Opracowanie własne

Zastosowanie narzędzia badawczego w postaci wykresu normalności (rys. 3) potwierdza brak rozkładu normalnego przychodów całkowitych w ujęciu dynamicznym.

Następnie dla celów badawczych użyto kolejnych narzędzi badawczych do analizy przychodów całkowitych w ujęciu miesięcznym w latach 2015-2019 w postaci: autokorelacji (rys. 4) i autokorelacji cząstkowej (rys. 5).




Rys. 4. Autokorelacja przychodów całkowitych w ujęciu miesięcznym w latach 2015-2019  
Źródło: Opracowanie własne


Oceną zastosowania autokorelacji jest stwierdzenie występowania w rozpatrywanych przychodach całkowitych tendencji, które powodują, iż analizowany szereg czasowy jest niestacjonarny (Korns, 2011).

Zaobserwowane tendencje widoczne są na rysunku 5. Ich oceną jest istnienie silnego trendu i sezonowości.

Kolejnym narzędziem wykorzystanym do analizy danych pierwotnych był wykres ramka-wąsy (rys. 6.).



Rys. 5. Autokorelacja cząstkowa przychodów całkowitych w ujęciu miesięcznym w latach 2015-2019  
Źródło: Opracowanie własne



Rys. 6. Wykres ramka-wąsy przychodów całkowitych w ujęciu miesięcznym w latach 2015-2019  
Źródło: Opracowanie własne

Z obserwacji danych przedstawionych na rysunku 6 wynika, że ich rozkład jest asymetryczny. W danych pierwotnych widoczne są wartości odstające, do których zaliczono: grudzień 2018, listopad 2019, październik 2019 oraz grudzień 2019.

Następnie, dla celów poglądowych, w tabeli 1 przeprowadzono analizę statystyki opisowej.

Tabela 1. Analiza statystyki opisowej danych pierwotnych

	N	Śred. aryt.	Śred. geom.	Śred. harm.	Mediana	Suma	Odch.std
<b>Przychody</b>	60	2 017 451,42	947 275,30	364 931,70	1 081 291,45	121 047 085,13	2 268 150
	<b>Min</b>	<b>Maks</b>	<b>Q25</b>	<b>Q75</b>	<b>Skośność</b>	<b>Kurtoza</b>	
<b>Przychody</b>	38 146,85	8 744 125,31	312 971,55	2 842 510,61	1,39	1,01	

Źródło: Opracowanie własne


Oceną przeprowadzonej w tabeli 1 analizy statystyki opisowej jest stwierdzenie, że średnia arytmetyczna danych pierwotnych (2 017 451,42) jest większa od mediany (1 081 291,45). Suma osiągniętych przychodów w ujęciu dynamicznym to kwota 121 047 084,13. Odchylenie standardowe od średniej arytmetycznej wyniosło 2 268 150. Rozkład analizowanych danych był prawostronnie asymetryczny, bardziej wysmukły do normalnego.

Dalszą częścią badań będzie przeprowadzenie wielowymiarowej analizy danych.

### 3. WIELOWYMIAROWA ANALIZA I OCENA PRZYCHODÓW

Wielowymiarową analizę danych pierwotnych przeprowadzono, grupując zmienne pierwotne na zmienne zależne i je objaśniające.

Pierwszą grupą zmiennych zależnych poddanych analizie były lata. Do analizy użyto skategoryzowanego wykresu ramka-wąsy (rys. 7).



Rys. 7. Skategoryzowany wykres ramka-wąsy przychodów całkowitych w ujęciu miesięcznym w latach 2015-2019 (grupa lata)

Źródło: Opracowanie własne

Oceną informacji zestawionych na rysunku 7 jest stwierdzenie zaobserwowania zjawiska trendu hiperbolicznego.

Następnie dla celów badawczych w tabeli 2 przeprowadzono analizę statystyki opisowej grupy zmiennych zależnych lat.

Tabela 2. Analiza statystyki opisowej w grupie lata

Lata	Śred. aryt.	N	Suma	% Sumy	Odch. std.	Wariancja
2015	258 009,37	12	3 096 112,49	2,56	163 197,61	26 633 458 861
2016	677 181,53	12	8 126 178,30	6,71	483 698,14	233 963 894 133
2017	1 380 827,64	12	16 569 931,62	13,69	934 150,21	872 636 618 518




<b>2018</b>	3 231 722,11	12	38 780 665,32	32,04	2 203 724,09	4 856 399 878 560
<b>2019</b>	4 539 516,45	12	54 474 197,40	45,00	2 697 635,33	7 277 236 372 861
<b>Ogółem</b>	<b>2 017 451,42</b>	<b>60</b>	<b>121 047 085,13</b>	<b>100,00</b>	<b>2 268 149,96</b>	<b>5 144 504 252 789</b>
<b>Lata</b>	<b>Min</b>	<b>Maks</b>	<b>Q25</b>	<b>Mediana</b>	<b>Q75</b>	
<b>2015</b>	38 146,85	548 691,73	121 559,70	249 106,95	371 115,84	
<b>2016</b>	56 272,69	1 461 934,78	236 013,51	637 445,30	1 086 762,06	
<b>2017</b>	133 178,80	2 880 363,43	543 902,37	1 327 138,85	2 182 619,08	
<b>2018</b>	286 561,05	6 783 962,57	1 289 020,52	3 137 517,21	5 030 844,33	
<b>2019</b>	640 349,06	8 744 125,31	2 249 613,27	4 501 829,52	6 796 726,13	
<b>Ogółem</b>	<b>38 146,85</b>	<b>8 744 125,31</b>	<b>312 971,55</b>	<b>1 081 291,45</b>	<b>2 842 510,61</b>	

Źródło: Opracowanie własne

Do analizy statyki opisowej użyto sześćdziesięciu zmiennych, które równomiernie występowały w każdej z pięciu grup zmiennych zależnych. Największa suma zmiennych zależnych została zaobserwowana w 2019 r. i wyniosła 54 474 197,40, a najniższa w 2015 r. – 3 096 112,49. Podobnie najwyższe odchylenie standardowe od średniej arytmetycznej odnotowano w 2019 r. – 2 697 635,33, a najniższe w 2015 r., które wyniosło 163 197,61. Średnia arytmetyczna była wyższa od mediany we wszystkich rozpatrywanych latach od 2015 do 2019. Dodatkowo najwyższą wartość maksymalną odnotowano w 2019 r. – 8 744 125,31, a najniższą w 2015 r. – 548 691,73.

Dalszym etapem wielowymiarowej analizy danych jest badanie grupy zmiennych zależnych miesięcy. Do tego celu użyto narzędzia badawczego w postaci wykresu ramka-wąsy (rys. 8).



Rys. 8. Skategoryzowany wykres ramka-wąsy przychodów całkowitych w ujęciu miesięcznym w latach 2015-2019 (grupa miesiące)

Źródło: Opracowanie własne

Z obserwacji rysunku 8 wynika, iż w danych pierwotnych zawartych w zmiennej zależnych miesiącach istnieje zjawisko sezonowości. Najniższa średnia arytmetyczna widoczna jest w każdym roku w styczniu, a najwyższa – w grudniu.

Dalszym etapem badań będzie przeprowadzenie analizy statystyki opisowej w grupie zmiennej zależnej miesiące (tabela 3).

Tabela 3. Analiza statystyki opisowej w grupie miesiące

Miesiące	Śred. arytm.	Przychody	Suma	% Sumy	Odch. std.	Wariancja
Styczeń	230 901,69	5	1 154 508,45	0,95	248 970,18	61 986 148 092,48
Luty	423 161,47	5	2 115 807,33	1,75	440 938,66	194 426 900 051,45
Marzec	720 578,33	5	3 602 891,65	2,98	738 227,66	544 980 073 529,66
Kwiecień	1 055 465,42	5	5 277 327,08	4,36	1 036 834,72	1 075 026 231 367,07
Maj	1 412 342,36	5	7 061 711,79	5,83	1 350 866,08	1 824 839 165 893,12
Czerwiec	1 767 236,94	5	8 836 184,68	7,30	1 639 355,44	2 687 486 274 393,65
Lipiec	2 173 978,19	5	10 869 890,94	8,98	1 955 973,91	3 825 833 940 454,83
Sierpień	2 465 785,08	5	12 328 925,38	10,19	2 185 620,02	4 776 934 873 838,90
Wrzesień	2 881 981,39	5	14 409 906,94	11,90	2 535 312,99	6 427 811 962 087,35
Październik	3 305 245,59	5	16 526 227,93	13,65	2 918 176,73	8 515 755 454 146,21
Listopad	3 688 925,03	5	18 444 625,14	15,24	3 226 201,72	10 408 377 511 144,40
Grudzień	4 083 815,56	5	20 419 077,82	16,87	3 529 480,74	12 457 234 297 181,50
Ogółem	2 017 451,42	60	121 047 085,13	100,00	2 268 149,96	5 144 504 252 789,39
Miesiące	Min	Maks	Q25	Mediana	Q75	
Styczeń	38 146,85	640 349,06	56 272,69	133 178,80	286 561,05	
Luty	65 354,63	1 138 816,46	109 446,03	263 021,62	539 168,59	
Marzec	100 228,24	1 884 644,10	186 887,92	437 032,72	994 098,67	
Kwiecień	142 891,16	2 614 582,44	285 139,10	650 772,02	1 583 942,36	
Maj	187 763,25	3 403 207,69	410 985,54	895 104,73	2 164 650,58	
Czerwiec	229 645,34	4 097 879,60	533 955,20	1 170 046,76	2 804 657,78	
Lipiec	268 568,55	4 905 779,43	740 935,39	1 484 230,94	3 470 376,63	
Sierpień	292 126,88	5 483 274,26	875 375,67	1 727 854,95	3 950 293,62	
Wrzesień	333 816,22	6 353 597,59	1 023 766,43	2 069 494,52	4 629 232,18	
Październik	408 415,46	7 239 854,67	1 149 757,69	2 295 743,64	5 432 456,47	
Listopad	480 464,18	7 968 086,79	1 291 721,86	2 563 087,49	6 141 264,82	
Grudzień	548 691,73	8 744 125,31	1 461 934,78	2 880 363,43	6 783 962,57	
Ogółem	<b>38 146,85</b>	<b>8 744 125,31</b>	<b>312 971,55</b>	<b>1 081 291,45</b>	<b>2 842 510,61</b>	

Źródło: Opracowanie własne

Oceną danych zawartych w tabeli 3 jest stwierdzenie, że do przeprowadzenia analizy statystyki opisowej użyto 60 zmiennych objaśniających łącznie dwanaście zmiennych zależnych. Na każdą zmienną zależną przypada po pięć różnych zmiennych objaśniających. Najwyższa suma przychodów całkowitych przypada na miesiąc grudnie i wynosi 20 419 077,82, co stanowi ok. 16,87% sumy przychodów całkowitych osiągniętych przez podmiot badań w ujęciu dynamicznym. W każdym roku w grudniu odnotowano najwyższe odchylenie standardowe – 3 529 480,74, wariancję – 12 457 234 297 181,50, średnią arytmetyczną – 4 083 815,56, oraz medianę – 6 783 962,57. Najniższym miesiącem, rozpatrując wariancję, odchylenie standardowe, sumy, medianę, był zdecydowanie styczeń.

Dalszą częścią badań będzie zbudowanie modelu regresji wielorakiej w celu potwierdzenia istnienia prawidłowości w postaci trendu i sezonowości w rozpatrywanych danych z przeszłości.

#### 4. MODEL REGRESJI WIELORAKIEJ

Model regresji wielorakiej zbudowano z czternastu predyktorów. Istotne przedstawiono w tabeli 4.

Tabela 4. Model regresji wielorakiej


N=58	R= ,94101284 R <sup>2</sup> = ,88550516 Popraw. R2= ,86403738 Błąd std. estymacji: 8406E2					
	b*	Bł. std.	b	Bł. std.	t (48)	p
W. wolny			185265	548487,5	0,33777	0,737006
t <sup>2</sup>	0,925424	0,079196	1928	165,0	11,68523	0,000000
Int	-0,182954	0,079477	-491097	213337,2	-2,30197	0,025718
VI	0,104799	0,051554	843888	415134,1	2,03281	0,047623
VII	0,144153	0,051596	1160782	415475,9	2,79386	0,007461
VIII	0,168446	0,051648	1356400	415894,4	3,26141	0,002044
IX	0,207462	0,051709	1670580	416383,6	4,01212	0,000210
X	0,246678	0,051779	1986358	416948,3	4,76404	0,000018
XI	0,280330	0,051860	2257344	417599,2	5,40553	0,000002
XII	0,314753	0,051953	2534531	418351,5	6,05838	0,000000

Źródło: Opracowanie własne

Zbudowany model regresji wielorakiej (tab. 4) potwierdza, że w danych z przeszłości dotyczących przychodów całkowitych istnieje zjawisko trendu i sezonowości.

Następnie postanowiono przeprowadzić analizę i ocenę reszt zbudowanego modelu regresji wielorakiej.


Pierwszym użytym narzędziem do analizy był wykres wartości przewidywanych i obserwowanych (rys. 9).



Rys. 9. Wykres liniowy wartości przewidywanych i obserwowanych  
Źródło: Opracowanie własne

Na podstawie rysunku 9 stwierdzono, że stopień dopasowania wartości przewidywanych do obserwowanych jest dobry.


Kolejnym użytym narzędziem do analizy był wykres liniowy reszt modelu regresji wielorakiej (rys. 10).



Rys. 10. Wykres liniowy reszt modelu regresji wielorakiej  
Źródło: Opracowanie własne


Reszty modelu regresji wielorakiej wykazują długie wąsy, a ich wartości są zarówno dodatnie, jak i ujemne.

Następnie do dalszych badań reszt modelu regresji wielorakiej użyto histogramu (rys. 11).



Rys. 11. Histogram reszt modelu regresji wielorakiej  
Źródło: Opracowanie własne

Rozkład zmiennych na histogramie (rys. 11) jest o charakterze normalnym. W celu potwierdzenia normalności zastosowano wykres normalności z testem Shapiro-Wilka (rys. 12).




Rys. 12. Wykres normalności z testem Shapiro-Wilka reszt modelu regresji wielorakiej  
Źródło: Opracowanie własne

Z informacji przedstawionych na wykresie normalności (rys. 12) wynika, że rozkład zmiennych pierwotnych jest normalny.


Następnie postanowiono zbadać zależności w opóźnieniach reszt modelu regresji wielorakiej. Do tego celu zastosowano dwa narzędzia badawcze w postaci: autokorelacji (rys. 13) i autokorelacji cząstkowej (rys. 14).

W opóźnieniach reszt modelu regresji wielorakiej nie zachodzi zjawisko białego szumu (rys. 13).



Rys. 13. Autokorelacja reszt modelu regresji wielorakiej  
Źródło: Opracowanie własne

Podobnie po zastosowaniu narzędzia autokorelacji cząstkowej (rys. 14) można zaobserwować brak stacjonarności reszt zbudowanego modelu regresji wielorakiej.




Rys. 14. Autokorelacja cząstkowa reszt modelu regresji wielorakiej  
Źródło: Opracowanie własne

Uzyskane oceny z przeprowadzonych analiz w postaci wykrycia trendu i sezonowości w ujęciu miesięcznym stały się przesłankami do zastosowania do prognozowania danych pierwotnych metody wygładzania wykładniczego Holta-Wintersa z trendem hiperbolicznym.

Wskutek krytycznej analizy literatury zaobserwowano, że w przypadku wykrycia trendu i sezonowości do prognozowania danych retrospektywnych używa się najczęściej metody wygładzania wykładniczego Holta-Wintersa. Prawidłowości w postaci trendu i sezonowości zaobserwowane w rozdziale 2 stały się przesłankami do ich prognozowania na przyszłość.

## 5. PROGNOZOWANIE METODĄ HOLTA-WINTERSA

Na rysunku 15 zestawiono prognozy danych pierwotnych na przyszłość wykonane metodą Holta-Wintersa z trendem hiperbolicznym.



Rys. 15. Prognozowanie przychodów całkowitych z wykorzystaniem metody wykładniczego Holta-Wintersa z trendem hiperbolicznym

Źródło: Opracowanie własne

W uzyskanej prognozie wykonanej metodą wykładniczego Holta-Wintersa zaobserwować można istnienie sezonowości oraz wzrostu danych dotyczących przychodów w 2020 r. w stosunku do rozpatrywanych lat poprzednich.

W tabeli 5 zestawiono prognozy uzyskane po zastosowaniu metody wykładniczego Holta-Wintersa z trendem hiperbolicznym w formie danych ilościowych w ujęciu miesięcznym.

Tabela 5. Prognoza przychodów na 2020 rok wykonanej metodą Holta-Wintersa

Lata	Miesiące	Prognoza
2020	Styczeń	878 529,22
2020	Luty	1 664 169,29
2020	Marzec	2 892 111,33
2020	Kwiecień	4 208 864,80
2020	Maj	5 563 521,78
2020	Czerwiec	6 810 671,77
2020	Lipiec	8 198 706,50
2020	Sierpień	9 124 150,86
2020	Wrzesień	10 485 191,36
2020	Październik	11 874 144,31
2020	Listopad	13 191 567,73
2020	Grudzień	14 759 193,98

Źródło: Opracowanie własne

Średnia arytmetyczna uzyskanej prognozy metodą wykładniczego Holta-Wintersa z trendem hiperbolicznym wynosi 7 470 902, natomiast mediana – 7 504 689. Rozkład prognozy jest symetryczny, bardziej spłaszczony od normalnego.

Następnie przeprowadzono analizę i ocenę reszt otrzymanej prognozy.

Pierwszym etapem badań reszt prognozy wykonanej metodą Holta-Wintersa była analiza błędów prognozy (tabela 6).


Tabela 6. Analiza błędów prognozy przychodów na 2020 r. wykonanej metodą Holta-Wintersa

Rodzaj błędu prognozy	Wynik
Średni błąd procentowy	-2,48
Średni bezwzględny błąd procentowy	7,92

Źródło: Opracowanie własne

Oceną analizy przeprowadzonej w tabeli 6 jest zaobserwowanie, że średni bezwzględny błąd prognozy jest na dobrym poziomie i wynosi 7,92.

Następnie przeprowadzono dalszą analizę i ocenę reszt prognozy. Na rysunku 16 przedstawiono wykres liniowy reszt prognozy.




Rys. 16. Wykres liniowy reszt prognozy z wykorzystaniem metody Holta-Wintersa z trendem hiperbolicznym

Źródło: Opracowanie własne

Z obserwacji wzrokowej rysunku 16 wynika, że w resztach prognozy wykonanej metodą Holta-Wintersa mogą występować zależności.

Następnie podjęto badania w kierunku określenia rozkładu otrzymanych reszt prognozowania. Do tego celu użyto narzędzi badawczych w postaci: histogramu (rys. 17), wykresu normalności z testem Shapiro-Wilka (rys. 18).






Rys. 17. Histogram reszt prognozy z wykorzystaniem metody Holta-Wintersa z trendem hiperbolicznym

Źródło: Opracowanie własne

Oceną histogramu (rys. 17) jest stwierdzenie, że rozkład reszt jest zbliżony do normalnego. Następnie zastosowano wykres normalności z testem Shapiro-Wilka (rys. 18).




Rys. 18. Wykres normalności z testem Shapiro-Wilka reszt prognozy z wykorzystaniem metody Holta-Wintersa z trendem hiperbolicznym

Źródło: Opracowanie własne

Ocena wykresu normalności to stwierdzenie, że rozkład reszt prognozy nie jest normalny.


Dalszym etapem badań jest poszukiwanie zależności w resztach otrzymanej prognozy. Do tego celu użyto dwóch narzędzi badawczych w postaci: autokorelacji (rys. 19) i autokorelacji cząstkowej (rys. 20).



Rys. 19. Autokorelacja reszt prognozy z wykorzystaniem metody Holta-Wintersa z trendem hiperbolicznym

Źródło: Opracowanie własne

Zastosowanie autokorelacji (rys. 19) pozwala na stwierdzenie, że w resztach otrzymanej prognozy brak jest białego szumu.



Rys. 20. Autokorelacja cząstkowa reszt prognozy z wykorzystaniem metody Holta-Wintersa z trendem hiperbolicznym

Źródło: Opracowanie własne

Brak białego szumu w resztach prognozy wykonanej metodą Holta-Wintersa widoczny jest również po użyciu autokorelacji cząstkowej (rys. 20).

## PODSUMOWANIE I WNIOSKI

W artykule wykonano analizę i ocenę danych retrospektywnych dotyczących uzyskiwanych przychodów przez podmiot badań w ujęciu dynamicznym. Następnie zastosowano wielowymiarową analizę danych oraz zbudowano model regresji wielorakiej. Oceną przeprowadzonych analiz było stwierdzenie, że rozpatrywany szereg czasowych danych retrospektywnych przychodów w ujęciu miesięcznym w latach 2015-2019 jest niestacjonarny i wykazuje tendencje w postaci trendu i sezonowości.

W artykule uzyskano odpowiedź na postawione następujące pytanie badawcze:

Czy przeprowadzenie analizy i oceny danych dotyczących przychodów całkowitych podmiotu badań w ujęciu dynamicznym pozwoli wykonać ich prognozowanie na przyszłość?

Zaobserwowane prawidłowości w postaci trendu i sezonowości stały się przesłankami do zastosowania do prognozowania posiadanych danych z przeszłości dotyczących zaewidencjonowanych przez podmiot badań uzyskanych przychodów na przyszłość. W **piątym punkcie merytorycznym** wykonano prognozowanie. Prognozy przedstawiono na wykresie liniowym (rys. 15) oraz zestawiono w tabeli 5. Następnie prognozy zostały poddane analizie i ocenie przez zastosowanie mierników oraz reszt przeprowadzonego prognozowania. Do tego celu zastosowano narzędzia badawcze w postaci: wykresu liniowego reszt prognozy, histogramu, wykresu normalności, autokorelacji i autokorelacji cząstkowej. Oceną przeprowadzonej analizy było stwierdzenie, że uzyskana prognoza jest dobra. Prognoza składała się z dwunastu danych (dwunastu miesięcy od stycznia do grudnia 2020 r.). Rozkład uzyskanej prognozy jest symetryczny, bardziej spłaszczony od normalnego. Średnia geometryczna uzyskanej prognozy to 5 718 460. Natomiast dolny kwartył był na poziomie 3 550 488, a górny 11 179 668.

Uzyskane prognozy mogą zostać wykorzystane w procesie planowania podmiotu badań oraz wspomogą poprawne zarządzanie posiadanymi środkami finansowymi w ujęciu dynamicznym.

## LITERATURA

- [1] BOX, G.E., JENKINS, G.M., REINSEL, G.C., & LJUNG, G.M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- [2] DITTMANN, P. (2003). *Prognozowanie w przedsiębiorstwie. Metody i ich zastosowanie*. Kraków: Oficyna Ekonomiczna.
- [3] DITTMANN, P., SZABELA-PASIERBIŃSKA, E., DITTMANN, I., SZPULAK, A. (2016). *Prognozowanie w zarządzaniu sprzedażą i finansami przedsiębiorstwa*. Wydawnictwo Nieoczywiste. Wolters Kluwer.
- [4] DU, X.F., LEUNG, S.C., ZHANG, J.L., & LAI, K.K. (2013). Demand forecasting of perishable farm products using support vector machine. *International Journal of Systems Science*, 44(3), 556-567.

- [5] GABRUSEWICZ, W. (2014). *Analiza finansowa przedsiębiorstwa: teoria i zastosowanie*. Polskie Wydawnictwo Ekonomiczne.
- [6] GRIFFIN, R.W. (2000). *Podstawy zarządzania organizacjami*. Warszawa: PWN.
- [7] HASTIE, T., TIBSHIRANI, R., & FRIEDMAN, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media.
- [8] HOFER, P., EISL, C., & MAYR, A. (2015). Forecasting in Austrian companies. *Journal of Applied Accounting Research*.
- [9] HOLT, C.C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International journal of forecasting*, 20(1), 5-10.
- [10] KORNIS, M.F. (2011). Accuracy in symbolic regression. In *Genetic Programming Theory and Practice IX* (pp. 129-151). Springer, New York, NY.
- [11] KOZICKI, B., WAŚCIŃSKI, T., BRZEZIŃSKI, M., & LISOWSKA, A. (2018). Cost forecast in a shipping company. *Transport means*, 1822-296.
- [12] KRUPSKI, R. (2004). Podstawy organizacji i zarządzania, wyd. 5. *Prace Naukowe Wałbrzyskiej Szkoły Zarządzania i Przedsiębiorczości, Seria Zarządzania i Marketing*. Wydawnictwo Ibis, Wrocław, 123-124.
- [13] MAIA, A.L.S., & DE CARVALHO, F.D.A. (2011). Holt's exponential smoothing and neural network models for forecasting interval-valued time series. *International Journal of Forecasting*, 27(3), 740-759.
- [14] SCHOLKOPF, B., & SMOLA, A.J. (2018). *Learning with kernels: support vector machines, regularization, optimization, and beyond*. Adaptive Computation and Machine Learning series.
- [15] SRIVASTAVA, R., AGARWAL, S., GARG, D., & PATNI, J. C. (2016). Capital market forecasting by using sentimental analysis. In *2016 2<sup>nd</sup> International Conference on Next Generation Computing Technologies (NGCT)* (pp. 09-12). IEEE.
- [16] WANG, C.H., & CHEN, J.Y. (2019). Demand forecasting and financial estimation considering the interactive dynamics of semiconductor supply-chain companies. *Computers & Industrial Engineering*, 138, 106104.