

Andrzej ŚWIDERSKI

Wojskowa Akademia Techniczna, Wydział Logistyki

MODELOWANIE PROCESÓW TRANSPORTOWYCH Z UWZGLĘDNIENIEM SEZONOWOŚCI PRZEWOZÓW

STRESZCZENIE

Sukces przedsiębiorstwa zależy od wielu czynników. Jednym z nich jest zdolność do spełnienia oczekiwań klientów i dopasowanie do potrzeb zgłaszanych przez rynek. Pomocne w ocenie popytu są metody i narzędzia matematyczne. Formułowane prognozy powinny brać pod uwagę wszystkie czynniki kształtujące zapotrzebowanie na dobra i usługi, jednak często są one trudne do zdefiniowania, nie tylko ze względu na znaczną ich liczbę, ale również na trudny do określenia wpływ poszczególnych zmiennych. W wielu przypadkach liczba złożonych zamówień silnie zależy od czasu, w którym są one składane. Potrzeby mogą być zróżnicowane w zależności od pory dnia, tygodnia, roku. Wówczas uaktywnia się tzw. sezonowość, której uwzględnienie jest bardzo istotne w przedsiębiorstwie i pozwala lepiej dostosować jego działalność do wymagań klientów.

W niniejszym artykule dokonano charakterystyki sezonowości popytu w firmie świadczącej usługi transportu krajowego, drogowego, realizowanego pojazdami wysokotonażowymi. Wskazano zasadność prowadzenia takich analiz i potencjalne korzyści.

Słowa kluczowe:

prognozowanie popytu, sezonowość, transport drogowy, model regresji wielorakiej

WSTĘP

Na popyt usług transportowych wpływa wiele czynników, które są przyczyną jego znacznej fluktuacji. Wahania te niejednokrotnie podlegają powtarzalnym zmianom, obserwowanym w krótkich, średnich i długich przedziałach czasu. Kształtuje je wiele czynników natury ekonomicznej, prawnej, społecznej czy klimatycznej. Ponadto silnie warunkuje je zmienność zapotrzebowania na produkty oferowane przez sektory, które branża TSL obsługuje.

Ta cykliczność zmian jest szansą dla przedsiębiorstw transportowych na lepsze dostosowanie do potrzeb rynku. Z pomocą wychodzą narzędzia i metody statystyczne oraz matematyczne, umożliwiające opisanie zachodzących zjawisk i wyciągnięcie na tej podstawie wniosków pozwalających na odpowiednie sformułowanie, a w razie potrzeby modyfikację strategii przedsiębiorstwa.

W artykule, na podstawie przedsiębiorstwa oferującego usługi transportowe, zaprezentowano metodę analizy popytu. W tym celu wykorzystano metodę regresji wielorakiej. Prognozę sporządzono w oparciu o zasze obserwacje, dotyczące zapotrzebowania na usługę przewozu w okresie ostatnich trzech lat. Zaprezentowane przedsiębiorstwo jest jedynie przykładowe. Analiza literatury wskazuje, że potrzeba modelowania poziomu wykorzystania środków transportowych jest istotna nie tylko dla przedsiębiorstw cywilnych [3, 5], ale również dla instytucji państwowych. Modele takie mogą znaleźć zastosowanie w prognozowaniu gotowości floty na przykład pojazdów straży pożarnej [3] czy sił zbrojnych [4, 6]. Sprawdzają się także w prognozach dotyczących płynności przejazdów i możliwych zakłóceń wynikających np. z zatłoczenia [15] czy wypadków drogowych [8, 17, 19].

METODA BADANIA

Analiza zjawisk i procesów jest możliwa do modelowania za pomocą procesów stochastycznych. Realizacja procesu stochastycznego w dziedzinie czasu, nazywana jest szeregiem czasowym [10, 22]. Jest to ciąg informacji uporządkowanych w czasie. Poszczególne pomiary są ewidencjonowane z dokładnym krokiem czasowym i stanowią zbiór obserwacji reprezentujących realizację badanego zjawiska i charakteryzujących zachodzące w nim zmiany. Konieczna jest również identyfikacja wszystkich występujących w szeregu elementów, którymi mogą być składowe systematyczne jak np. trend, wahania okresowe lub cykliczne oraz składowe przypadkowe – losowe. Proces ten nazywa się dekompozycją szeregu czasowego [3, 16].

W analizowanym przykładzie wykorzystano regresję wieloraką. Należy ona do grupy modeli analitycznych, w których konieczne jest odnalezienie matematycznych zależności - funkcji odzwierciedlających realizację procesu, co pozwala ponadto na rozszerzenie analiz również na argumenty spoza zakresu zgromadzonych danych empirycznych i określenie, jak badane zjawisko będzie się kształtowało w przyszłości. Estymacja polega na odnalezieniu właściwej funkcji trendu, a następnie opisaniu i wyodrębnieniu (jeśli istnieją) wahań sezonowych i cyklicznych. Najprostszą postacią trendu jest funkcja liniowa, jednak trend może być również estymowany za pomocą innej funkcji, na przykład wykładniczej, kwadratowej lub potęgowej, w zależności od struktury badanego zjawiska. Funkcja trendu nie jest jednak wystarczająca, jeżeli

w procesie występują wahania. Jak już wspomniano wyżej mogą one dotyczyć zmian wynikających z kalendarza, determinującego pewien rytm zjawisk: dzienny, tygodniowy, miesięczny itp. wówczas są to wahania sezonowe lub kształtowanych przez czynniki natury ekonomicznej – czyli wahań cyklicznych. W procesie estymacji parametrów modelu wykorzystuje się klasyczną metodę najmniejszych kwadratów (KMNK) lub metodę największej wiarygodności (MNW) [2, 6].

Jednym z analitycznych sposobów przyporządkowania wartości zmiennej zależnej konkretnym wartościom zmiennych niezależnych jest regresja. Jej najprostszym rodzajem jest liniowa regresja prosta, opisująca zależności między zmiennymi za pomocą linii prostej (1).

$$\hat{y} = \beta_0 + \beta_1 x + \varepsilon \quad (1)$$

gdzie:

β_1 - współczynnik kierunkowy,
 β_0 - wyraz wolny (punkt przecięcia z osią rzędnych),
 x - zmienna niezależna,
 y - zmienna zależna (objaśniana, przewidywana),
 ε - błąd losowy.

Jeżeli zmiennych objaśniających jest więcej, wówczas mamy do czynienia z regresją wieloraką, a liniowy model regresji wielorakiej przyjmuje postać (2):

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (2)$$

gdzie:

β_0 - wyraz wolny,
 β_i - parametry modelu – współczynniki regresji
 x - zmienna niezależna,
 y - zmienna zależna (objaśniana, przewidywana),
 ε - błąd losowy.

Współczynniki regresji opisują, o ile zmieni się średnio wartość zmiennej zależnej y , jeżeli wartość zmiennej niezależnej x , której dotyczą, zmieni się o jednostkę, przy założeniu ustalonego poziomu pozostałych zmiennych niezależnych.


Zmienne niezależne w analizie zjawisk ekonomicznych często nie mają charakteru ilościowego, ale jakościowy, tak jak w analizowanym przykładzie. W takiej sytuacji konieczne jest ich przekodowanie na zmienne zero-jedynkowe. Ponieważ ich liczba jest ograniczona, nie mogą być one traktowane w sposób przyjęty dla zmiennych ciągłych w regresji, co wynika z faktu, nie mają one sensu ekonomicznego, a obliczone współczynniki modelu nie posiada-

ją interpretacji ekonomicznej. Wówczas taka zmienna jakościowa lub dyskretna, posiadająca od kilku czy kilkunastu kategorii, kodowana jest na odpowiednią liczbę q zmiennych binarnych (zero-jedynkowych), które są używane w równaniu regresji. Aby jednak możliwe było zastosowanie metody MNK do estymacji modelu należy wykorzystać $q - 1$ sztucznych zmiennych, gdyż wprowadzenie q zmiennych, a więc w ilości równej zmiennym objaśniającym spowoduje, że wystąpi liniowa zależność między regresorami, a macierz $X'X$ będzie osobliwa. Wynika to z faktu, że zmienne zerojedynkowe sumują się do jedności. Takie zjawisko określane jest w literaturze ekonometrycznej jako pułapka związana ze zmiennymi zero-jedynkowymi (*dummyvariable trap*) [15, 17]. Taki model nie jest możliwy do oszacowania i dlatego liczba zmiennych sztucznych musi być zawsze mniejsza o jeden w stosunku do liczby kategorii q (poziomów), zidentyfikowanych dla danego atrybutu (cechy). Tylko wówczas estymowany model jest prawidłowy i składa się z wyrazu wolnego β_0 , sumy iloczynów parametrów strukturalnych i zmiennych binarnych D_k numer $k=1; q$, reprezentujących sezonowość, oraz składnika losowego ε (3).

$$\hat{y} = \beta_0 + \beta_1 t + \delta_1 D_1 + \dots + \delta_k D_k + \varepsilon$$

PODMIOT BADANIA

Analizie poddano przewozy realizowane w przedsiębiorstwie na przestrzeni ostatnich trzech lat. Dysponuje ono 30 pojazdami o dopuszczalnej ładowności wynoszącej 24 t. Ich przebieg przedstawiono na rys.1.



Rys. 1. Popyt na usługi transportowe w latach 2016-2018

źródło: opracowanie własne

Na wykresie zauważalna jest duża sezonowość przewozów. Potwierdzają to wybrane miary statystyki opisowej, obliczone dla poszczególnych miesięcy, przedstawione w tab. 1.


Tabela 1. Podstawowe miary statystyk opisowych

miesiąc	Średnia [tyś. km]	Mediana [tyś. km]	Minimum [tyś. km]	Maksimum [tyś. km]	Odch.std [tyś. km]	Wsp.zmn. [%]
styczeń	172	167	160	190	15,70	9,11
luty	185	187	172	197	12,58	6,79
marzec	213	213	210	215	2,52	1,18
kwiecień	217	218	216	218	1,15	0,53
maj	221	222	210	230	10,07	4,56
czerwiec	238	239	236	240	2,08	0,87
lipiec	248	250	240	255	7,64	3,08
sierpień	294	294	289	298	4,51	1,54
wrzesień	282	282	280	285	2,52	0,89
październik	240	240	230	250	10,00	4,17
listopad	208	210	200	215	7,64	3,67
grudzień	201	200,5	197	204	4,95	2,47

źródło: opracowanie własne

Największe potrzeby transportowe występują w sierpniu i we wrześniu. Najniższe wskazania natomiast odnotowano w styczniu i lutym. Różnice zapotrzebowania dla poszczególnych miesięcy dobrze oddaje przedstawiony na rys. 2 wykres zmienności miesięcznej.


Przygotowanie przedsiębiorstwa na pojawiające się wahania wymaga zatem ich uwzględnienia w prognozowanym popycie. Umożliwia to wspomniany model regresji wielorakiej, dokładnie taki jej rodzaj, w którym zostaną wykorzystane zmienne binarne.



Rys. 2 Wykres zmienności średnich potrzeb transportowych w poszczególnych miesiącach

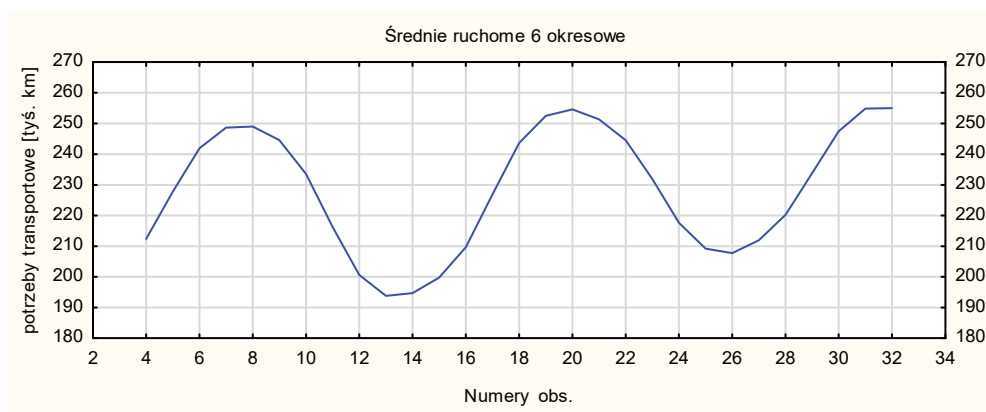
źródło: opracowanie własne

Ponadto Rys. 1 sugeruje występowanie tendencji rozwojowej, jednak wahania sezonowe utrudniają nieco jej wizualne wyodrębnienie. Aby ocenić występowanie trendu w średniej wartości szeregu zaproponowano zastosowanie mechanicznego sposobu jego wyznaczania za pomocą średnich ruchomych. Wyznaczono proste średnie ruchome 3 okresowe, 6 okresowe i 12 okresowe i otrzymano wykresy jak na Rys. 3, Rys. 4, Rys. 5.




Rys. 3. Średnie ruchome 3 okresowe

źródło: opracowanie własne



Rys. 4. Średnie ruchome 6 okresowe

Źródło: opracowanie własne



Rys. 5 Średnie ruchome 12 okresowe

Źródło: opracowanie własne

Już praktycznie na rysunku ze średnimi ruchomymi 6 okresowymi wi-
 dać istnienie trendu i jego wzrostowy charakter, co ostatecznie potwierdza
 wykres ze średnimi 12 okresowymi. Powyższe analizy wskazują zatem, że mo-
 del powinien opisywać długookresowy trend i krótkookresową sezonowość,
 dla poszczególnych miesięcy w roku. Jak już wspomniano wcześniej, jakości-
 owoy charakter zmiennej objaśniającej powoduje konieczność oszacowania mo-
 delu w którym liczba zmiennych będzie o jeden mniejsza. Taki model składa się
 z wyrazu wolnego, trendu, oraz sumy jedenastu iloczynów parametrów struk-
 turalnych i zmiennych binarnych D_k dla $k \in \{1, 11\}$ reprezentujących sezonowość,
 jak w poniższym wzorze (4).

$$y = a_0 + a_1 t + b_1 D_1 + \dots + b_k D_k \quad (4)$$


W większości publikacji proponuje się estymację modelu pomniejszonego o zmienną o najniższym wskazaniu [10, 16]. W tym przypadku jest to styczeń. Oznacza to, że oszacowania parametrów sezonowych będą odnosić się do „styczniowego” poziomu. Dlatego wszystkie wartości parametrów dla poszczególnych miesięcy będą dodatnie, gdyż każda z nich będzie miała wyższy od styczniowego poziom. Wyniki estymacji parametrów funkcji regresji wielorakiej i błędy oszacowań przedstawia Tab. 2.

Tabela 2. Wyniki estymacji modelu regresji wielorakiej

N=35	R ² = 0,97 Popraw. R ² = 0,96 F(12,22)=66,750 p<,00000 Błąd std. estymacji: 7,3084			
	b	Bł. std. z b	t(22)	p
W. wolny	167,93	4,54	37,01	0,000000
trend	0,34	0,13	2,64	0,014975
lutym	12,66	5,97	2,12	0,045404
marzec	39,66	5,97	6,64	0,000001
kwiecień	43,98	5,98	7,36	0,000000
maj	46,98	5,99	7,84	0,000000
czerwiec	64,31	6,00	10,71	0,000000
lipiec	73,97	6,02	12,29	0,000000
sierpień	118,96	6,03	19,71	0,000000
wrzesień	107,29	6,06	17,72	0,000000
październik	64,62	6,08	10,63	0,000000
listopad	32,61	6,10	5,34	0,000023
grudzień	26,47	6,70	3,95	0,000682

źródło: opracowanie własne

Skorygowany współczynnik determinacji, określający jaki procent zmienności zmiennej zależnej (Y - objaśnianej) jest wyjaśniany za pomocą zmiennej niezależnej (X - objaśniającej) jest satysfakcjonujący i wynosi 96%, błędy oszacowań parametrów są małe, na poziomie około 6%. Ponadto o jakości modelu świadczy fakt, że wszystkie oszacowane parametry są statystycznie istotne, co jest zadowalające również ze względu na interpretację merytoryczną modelu i brak konieczności usuwania nieistotnych zmiennych objaśniających. Wykres wartości empirycznych i prognozowanych przedstawia Rys. 6.



Rys. 6 wykres wartości empirycznych i prognozowanych

źródło: opracowanie własne

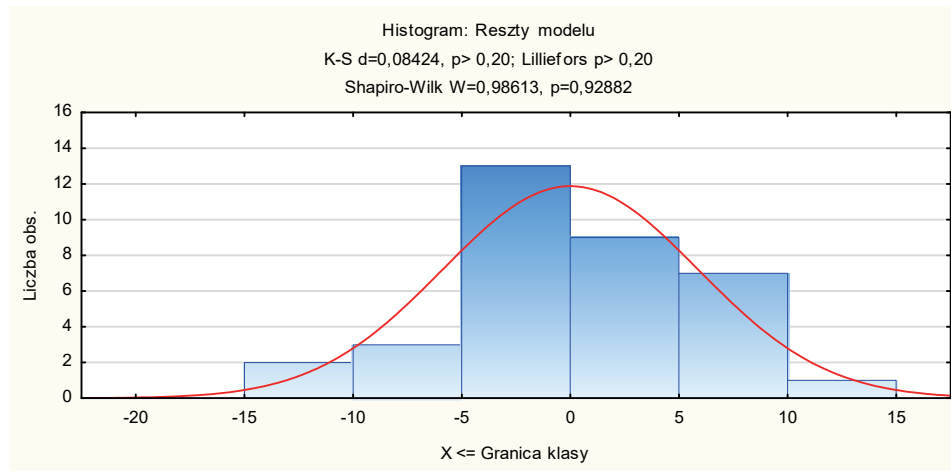
Prognoza najgorzej sprawdziła się dla stycznia, jest to miesiąc w którym otrzymane błędy prognozy są największe. Ma na to wpływ zarówno niewielka liczba obserwacji, jak i najwyższy spośród wszystkich współczynnik zmienności. Dalsze badania i estymacja modelu z dłuższego okresu pozwoliłaby na większą wiarygodność modelu.

DIAGNOSTYKA MODELU

Podstawą oceny dokładności dopasowania funkcji teoretycznej do danych empirycznych jest analiza różnic pomiędzy wartościami empirycznymi a teoretycznymi, zwanymi resztami modelu. Potwierdzenie poprawności modelu regresji wymaga zatem sprawdzenia podstawowych założeń dotyczących reszt do których należy badanie normalności ich rozkładu oraz istnienia istotnych zależności funkcji autokorelacji.

Na rys. 7 zaprezentowano histogram rozkładu reszt który pokazuje, że rozkład jest zbliżony do normalnego, co potwierdza obliczona statystyka testu Shapiro-Wilka, której wartość obliczeniowa wynosi 0,9861, natomiast prawdopodobieństwo testowe $p=0,9288$ co oznacza, że nie istnieją podstawy do odrzucenia hipotezy H_0 na poziomie istotności $\alpha = 0,05$ która mówi o tym, że rozkład zmiennej jest zbliżony do normalnego. Podobne wyniki uzyskano dla

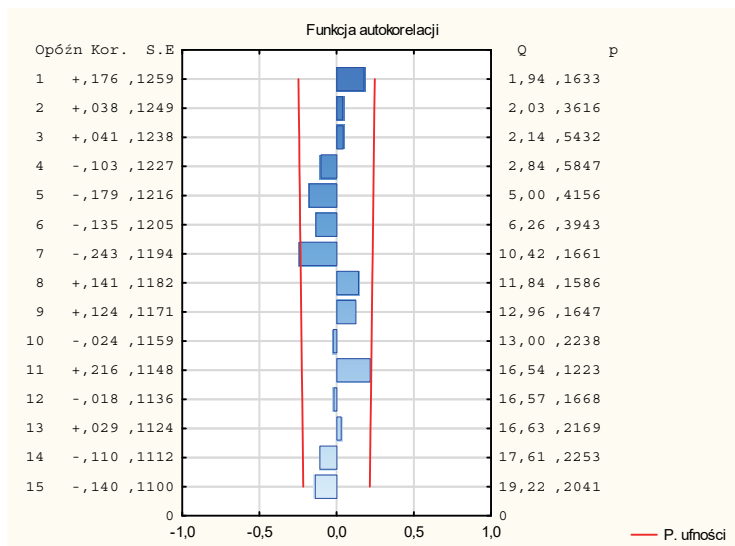
testu Lillieforsa dla którego wartość obliczeniowa wynosi 0,08424, z wartością $p > 0,2$ potwierdzając, że rozkład reszt jest normalny.



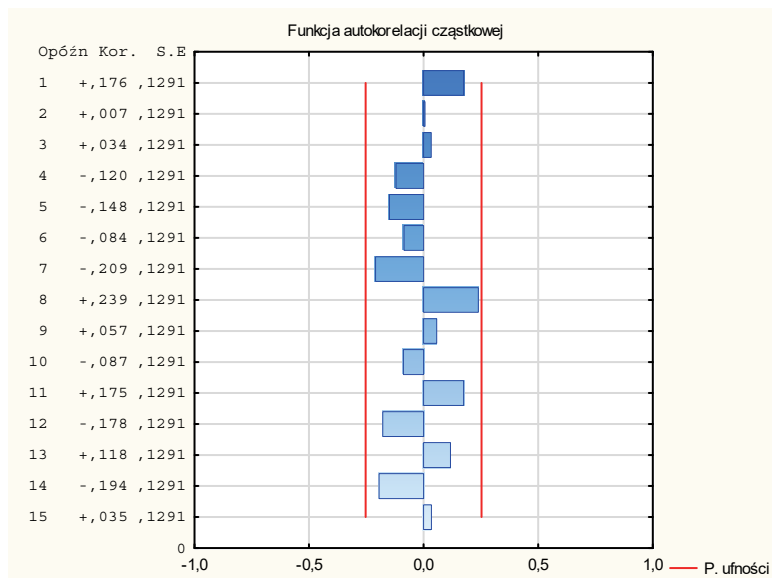
Rys. 7. Histogram reszt modelu

źródło: opracowanie własne

Kolejnym czynnikiem, decydującym o poprawności modelu, jest brak istotnych statystycznie korelacji pomiędzy wartościami reszt czyli potwierdzenie, że nie pozostały niewyjaśnione modelem zależności. W tym celu dokonano badania wykresów funkcji autokorelacji i autokorelacji cząstkowej, przedstawionych na rys. 8 oraz rys. 9. Ponieważ wszystkie wartości funkcji są statystycznie nieistotne, potwierdzono w ten sposób prawidłową budowę modelu.




Rys. 8. Funkcja autokorelacji reszt modelu regresji
 źródło: opracowanie własne



Rys. 9. Funkcja autokorelacji cząstkowej reszt modelu regresji
 źródło: opracowanie własne

Na podstawie otrzymanych wyników zaproponowano także prognozę potrzeb transportowych na rok 2019, przedstawioną na rys. 10.



Rys. 10. Prognoza potrzeb przewozowych na rok 2019

źródło: opracowanie własne

Analiza wykresu na rys 10 ponownie wskazuje na niedoszacowanie prognozy na styczeń. Dla wielu branż jest to trudny moment, co ma swoje odzwierciedlenie w popycie na usługi transportowe.

Należy także podkreślić, że każda prognoza musi być monitorowana, weryfikowana i dostosowywana do zmieniającego się dynamicznie rynku. Ponadto funkcja prognoz jest jedynie doradcza, pozwala wskazać główne kierunki zmian i stanowi doskonałe wsparcie procesów zarządzania. Nie dostarcza jednak gotowych decyzji.

PODSUMOWANIE

Przeprowadzone badanie pokazało możliwość prognozowania potrzeb przewozowych w firmie transportowej z wykorzystaniem regresji wielorakiej. Zaproponowany model ujawnił nie tylko wyraźną sezonowość procesu, ale także istniejącą tendencję wzrostową. Dla przedsiębiorstwa, szczególnie takiego, które eksploatuje własny transport (jak badane), jest to informacja bardzo ważna. Po pierwsze pokazuje, że istnieją miesiące, w których posiadany poten-

cjał transportowy może nie być w pełni wykorzystany, a z drugiej strony, że stale rosnący popyt może w najbliższej przyszłości spowodować, że posiadana flota pojazdów nie zaspokoi w pełni potrzeb, szczególnie w miesiącach w których są one największe. Oznacza to, że konieczna jest weryfikacja strategii transportowej przedsiębiorstwa i zaproponowanie kierunków z jednej strony minimalizujących poziom niewykorzystanego potencjału pojazdów, a z drugiej zabezpieczający interesy firmy w przypadku popytu większego niż możliwości transportowe.

BIBLIOGRAFIA

- [1] Bielińska, E. *Prognozowanie ciągów czasowych*. Wydawnictwo Politechniki Śląskiej, Gliwice 2007.
- [2] Bitner A. *Konstrukcja modelu regresji wielorakiej przy wycenie nieruchomości*, Acta Scientiarum Polonorum. Administratio Locorum, nr 4(6), 2007, s. 59-66.
- [3] Borucka A. *Forecasting of fire risk with regard to readiness of rescue and fire-fighting vehicles*, Interdisciplinary Management Research XIV, Croatia, 2018, s. 397-395.
- [4] Borucka A. *Funkcjonowanie wojskowych oddziałów gospodarczych w nowym systemie logistycznym sił zbrojnych*, „Logistyka”, 2013, nr 6, s. 39-48.
- [5] Borucka A. *Markov models in the analysis of the operation process of transport means*, Proceedings of the ICTTE International Journal For Traffic And Transport Engineering Conference, Belgrad, 2018, s. 1073-1082.
- [6] Borucka A. *Model of the operation process of aircraft in the transport system*, Proceedings of the ICTTE International Journal For Traffic And Transport Engineering Conference, 2018, s. 22-30.
- [7] Borucka A. *Przewóz osób w Polsce w świetle zmian legislacyjnych*, „Logistyka” nr 6, 2014, s. 468-475.
- [8] Borucka A. *Risk Analysis of Accidents in Poland Based on ARIMA Model*, Transport Means 2018, Proceedings of the 22nd International Scientific Conference part I, Lithuania, 2018, s. 162-166.
- [9] Borucka A. *Three-state Markov model of using transport means*, Proceedings of the 18th International Scientific Conference, Business Logistics In Modern Management, Croatia, 2018, s. 3-19.

- [10] Dittmann P. *Metody prognozowania sprzedaży w przedsiębiorstwie* Wydawnictwo Akademii Ekonomicznej, Wrocław 2000.
- [11] Dittmann P., Szabela-Pasierbińska E., Dittman I., Szpulak A. *Prognozowanie w zarządzaniu sprzedażą i finansami przedsiębiorstwa*, Wolters Kluwer Polska Sp. Z o.o., Warszawa 2011.
- [12] StatSoft, *Elektroniczny Podręcznik Statystyki*, Kraków, 2006 [http://www.statsoft.pl/textbook/stathome.html]
- [13] Maciąg A., Pietroń R., Kukla S. *Prognozowanie i symulacja w przedsiębiorstwie*, Polskie Wydawnictwo Ekonomiczne, Warszawa 2013.
- [14] Mikosz B., Borucka A. *Organizacja gospodarki odpadami w siłach zbrojnych na tle zmian militarnych i nowych wyzwań stawianych polskiej armii*, „Archiwum Gospodarki Odpadami i Ochrony Środowiska”, 2008, nr 8, s. 1-12.
- [15] Mitkowsz., Borucka A. *Mathematical model of travel times related to a transport congestion: an example of the capital city of Poland – Warsaw*, Proceedings of the 18th International Scientific Conference, Business Logistics In Modern Management, Croatia, 2018, s. 501-526.
- [16] Sokołowski, A. *Prognozowanie i analiza szeregów czasowych*. Materiały szkoleniowe StatSoft Polska, Kraków 2016.
- [17] Świdorski A., Borucka A. *Mathematical Analysis of Factors Affecting the Road Safety in Selected Polish Region*, Transport Means, Proceedings of the 22nd International Scientific Conference part II, Lithuania, 2018, s. 651- 654.
- [18] Świdorski A., Borucka A., Jacyna-Gołda I., Szczepański E. *Wear of brake system components in various operating conditions of vehicle in the transport company*, „Eksplatacja i Niezawodność – Maintenance and Reliability”, z. 1, nr 21, 2019, s. 1-9. [http://dx.doi.org/10.17531/ein.2019.1.1.]
- [19] Świdorski A., Borucka A., Skoczyński P. *Characteristics and Assessment of the Road Safety Level in Poland with Multiple Regression Model*, Transport Means, Proceedings of the 22nd International Scientific Conference part I, Lithuania 2018, s. 92 – 97.
- [20] Waśniewski T., Borucka A. *Sieciowe rozwiązania w łańcuchu dostaw w oparciu o technologię radiowej identyfikacji towarów*, „Systemy Logistyczne Wojsk” nr. 37, 2011, s. 223 – 233.

- [21] Wielgosik M., Borucka A. *Istota i znaczenie służby przygotowawczej i szkolenia rezerw*, „Systemy Logistyczne Wojsk”, 2016, nr 45, s. 51-66.
- [22] Żurek J., Ziółkowski J., Borucka A. *A method for determination of combat vehicles availability by means of statistic and econometric analysis*, Safety and Reliability. Theory and Applications, ESREL2017, s. 2925-2934.
- [23] Żurek J., Ziółkowski J., Borucka A. *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, ESREL2017, s. 2343-2352.
- [24] Żurek J., Ziółkowski J., Borucka A. *Research of automotive vehicles operation process using the Markov model*, Safety and Reliability. Theory and Applications, ESREL2017, s. 2353-2362.

MODELING OF TRANSPORT PROCESSES WITH REGARD TO SEASONALITY OF TRANSPORT

ABSTRACT

The company's success depends on many factors. One of them is the ability to meet the customers' expectations and adjust to the needs reported by market. Mathematical methods and tools are helpful in assessing demand. Forecasts should take into account all factors shaping the demand for goods and services, but they are often difficult to define, not only because of their large number, but also due to the impact of individual variables, which is difficult to determine. In many cases, the number of placed orders strongly depends on the time at which they are submitted. The needs can vary according to the time of day, week and year. Then we are dealing with the so-called seasonality, the inclusion of which is very important in the company and enables to better adapt its activity to the customers' requirements.

This article describes the seasonality of demand in a company providing domestic and road transport services with high-tonnage vehicles. The validity of such analyses and potential benefits were indicated.

Keywords:

demand forecasting, seasonality, road transport, multiple regression