

Arkadiusz JÓŹWIAK  
Paulina OWCZAREK  
Leon PROCHOWSKI  
Andrzej ŚWIDERSKI

## ANALYSIS OF THE IMPACT OF THE USE TIME OF N1 MOTOR VEHICLES ON THE ECONOMIC EFFICIENCY OF THEIR MAINTENANCE

### BADANIE WPŁYWU CZASU WYKORZYSTANIA SAMOCHODÓW KATEGORII N1 NA EFEKTYWNOŚĆ EKONOMICZNĄ ICH EKSPLOATACJI\*

*The efficiency of operation of motor vehicles with a DMC (Permissible Laden Mass) <3.5 tonnes is considered. These are vehicles belonging motor vehicles of category N1, usually referred to as delivery vehicles. The results of observations on the implementation of transport orders in 7 transport companies from the MŚP (Small and Middle-size Companies) sector were used to conduct the effectiveness analysis. The research group covered 24 vehicles that implementation transport orders in the urban zone and in the immediate vicinity of the city. Information was collected on a monthly basis. During the analysis of economic efficiency the income measures (absolute and relative) were used. The calculations were carried out using the model of the vehicle operation process in the form of a neural network, in which a set of 12 input variables and 3 output variables were taken into account. Using the Statistica 13.3 computer program and defining the group and factors describing the process of implementation of individual transport tasks, the developed neural network model enabled searching for the impact of selected operational factors on the economic efficiency of N1 category cars. The calculations showed a significant impact of the number of vehicle days in a month, the weight of the load, as well as the time of year. The obtained calculation results showed the specific features of the impact of the number of working days on revenue in a transport company. The increase in the number of working days favors the increase in income in a limited way, and this restriction depends, among others since the time of year.*

**Keywords:** operation of vehicles, motor vehicles of category N1, economic efficiency, neural networks.

*Rozważa się efektywność eksploatacji samochodów ciężarowych o DMC < 3,5 tony. Są to pojazdy należące do kategorii N1 (według Dyrektywy 2007/46/WE) zwykle nazywane samochodami dostawczymi. Do prowadzonej analizy efektywności wykorzystano wyniki obserwacji z realizacji zleceń przewozowych w 7 firmach transportowych z sektora MŚP. Grupa badawcza objęła 24 pojazdy, które wykonywały zadania transportowe w strefie miejskiej i w najbliższym otoczeniu miasta. Informacje gromadzono w cyklach miesięcznych. Podczas analizy efektywności ekonomicznej zastosowano kilka miar przychodu (bezwzględny i względny). Obliczenia prowadzono przy wykorzystaniu modelu procesu eksploatacji pojazdów w postaci sieci neuronowej, w której brano pod uwagę zbiór 12 zmiennych wejściowych i 3 zmienne wyjściowe. Stosując program komputerowy Statistica 13.3 oraz zdefiniowanie grupy i czynniki opisujące proces realizacji poszczególnych zadań transportowych, opracowany model sieci neuronowej umożliwił poszukiwanie wpływu wybranych czynników eksploatacyjnych na efektywność ekonomiczną samochodów kategorii N1. Przeprowadzone obliczenia pokazały istotny wpływ liczby dni pracy pojazdów w miesiącu, masę ładunku, a także porę roku. Uzyskane wyniki obliczeń pokazały specyficzne cechy wpływu liczby dni pracy na przychód w firmie transportowej. Wzrost liczby dni pracy sprzyja wzrostowi przychodu w sposób ograniczony, a to ograniczenie zależy m.in. od pory roku.*

**Słowa kluczowe:** eksploatacja samochodów, pojazdy samochodowe kategorii N1, efektywność ekonomiczna, sieci neuronowe.

#### 1. Introduction

The specificity of the use of N1 motor vehicles constantly raises a lot of controversy, and in the area of legal conditions there are still a number of ambiguities, which affects the existence of rather negligible amount of literature on this subject. Every month there is new information regarding the statistics of the Main Road Transport Inspectorate about the results of N1 category motor vehicles inspections. For several years, the percentage of vehicles with a load exceeding their permissible capacity in relation to the category N1 vehicles inspected has remained on average at the 93% level (table 1) [19]. It is a

fact that the Road Transport Inspectorate usually checks heavy goods vehicles over 3.5 tons, while N1 category vehicles only when it considers that there is a clear suspicion of committing a specific offense. The number of vehicles inspected is negligible, but the percentage ratio of vehicles with a load exceeding their permissible load capacity of up to 3.5 tons may indicate the existence of a complex problem that should be subject to detailed analysis.

Therefore, it becomes justified to be interested in the subject of increasing the profits from operation of the N1 category motor vehicles. Reproducing and simplifying real phenomena in the form of a model becomes an important element in the search for effective methods to

(\*) Tekst artykułu w polskiej wersji językowej dostępny w elektronicznym wydaniu kwartalnika na stronie [www.ein.org.pl](http://www.ein.org.pl)

Table 1. Percentage share of vehicles with a load exceeding their permissible capacity in relation to the N1 category vehicles tested [19]

	2014	2015	2016	2017
Number of all vehicles with GVW up to 3.5 t	2 399 323	2 447 764	2 515 751	2 574 312
Number of vehicles checked with GVW up to 3.5 t	6 685	6 507	7 594	10 048
Number of tickets issued for vehicles with a load exceeding their maximum capacity	6 135	6 172	6 172	9 396
Percentage share	92%	95%	92%	94%

describe problems and disturbances in the process of operating and servicing motor vehicles. As a result, it makes it easier to find ways to increase the economic efficiency of transport companies.

In the article, the subject of research is the effectiveness of operation of the N1 category cars, which according to [27] are defined as vehicles designed and constructed for transporting loads and having a maximum total weight not exceeding 3.5 tons (GVW up to 3.5 t). In practice, this type of vehicle is referred to as delivery vehicles, which is why this term will be used interchangeably later in the article.

Planning and implementing the process of using motor vehicles in a complex transport system is associated with solving multi-criteria decision problems, which focus on, among the others minimizing costs and achieving maximum profit. This issue concerns the issues of two basic elements of the operation process, i.e. the use and maintenance of motor vehicles. Effective use of transport means in every enterprise is one of the main ways to achieve competitive advantage.

Extensive analyzes of the motor vehicles operation process most often relate to minimizing the costs associated with their use and ensuring maximum reliability of the transport system, as well as the impact of operating the vehicles on the natural environment [21], or safety aspect [20]. Whereas the assessment of the intensity of motor vehicle operation is carried out taking into account, inter alia, mileage values, engine capacity, vehicle's age [18], repair costs, revenues [16], technical availability, intensity of motor vehicle use [6]. Due to the random nature of vehicle failures, the knowledge of stochastic processes is necessary to maintain their efficient and safe operation [2].

Modelling and assessment of such complex processes based on classic mathematical models and techniques of reliability theory may be difficult to carry out and not bring the expected results due to the large amount of quantitative and qualitative data and due to the dynamically changing conditions of the vehicle operation system. In such a case, other computational methods are proposed, e.g. models using Markov processes or reliable phase diagrams, a Petri network model or Monte Carlo simulation processes [13], an algorithm of resistance clonal selection [5].

Considering the degree of complexity of the studied problem and the increasing use of artificial intelligence methods to solve this type of task, the goal of this study is to assess the economic efficiency of transport companies using a neural network. The evaluation is focused on transport companies operating for package cargo transport in urban and suburban areas. The work uses several measures of revenue in transport activities described later in this work.

Wherever there are no grounds for linear approximation of occurring phenomena and processes, usually when solving difficult and troublesome evaluation issues, including efficiency of car operation, it may be rational to refer to neural networks or other artificial intelligence algorithms (i.e. models that map non-linear relationships) [7], [9], [10], [24]. Artificial neural networks are one of the techniques used by artificial intelligence. There are also other uses of artificial intelligence in transport. For example: for assessing the quality of transport means, for optimizing travel routes [11], or for evaluating the configuration of transport service management [23].

## 2. Cost analysis of a transport enterprise with a fleet of N1 category motor vehicles

The transport service provider is still selected by the minimum price criterion as the first choice. High competition and constantly growing requirements of the transport market force carriers to constantly search for methods to minimize the costs of a transport company. Generating revenues at the transport companies is primarily based on the intensity of the vehicle operation. As a rule, they are proportional to the number of kilometers traveled, load weight or hours worked. The intensive operation of vehicles generates not only an increase in revenues, but also costs, which is why it is extremely important to carry out their detailed analysis.

In enterprises, including transport ones, one of the most commonly used cost sharing methods is their generic system, containing 7 groups, which are also the names of synthetic accounts: depreciation, consumption of materials and energy, external services, taxes and fees, salaries, social insurance and other benefits, other costs (generic ones).

According to many publications, the costs of external services represent the largest percentage in relation to all costs of the transport company [15]. In this study, the research subjects are micro, small and medium enterprises (micro and SMEs), therefore the cost structure will be slightly different from the general classification of generic type of costs of the enterprises. The reason for this could be, for example, the fact that micro and SMEs only have their own, not leased rolling stock, which provides transport services directly without the participation of outsourcing companies. Issues related in detail to the costs of road freight transport enterprises are of interest to many authors [1], [4], [8], [12], [15], [26] who most often reduce them to four basic generic groups and determine their percentage values in relation to other costs:

- depreciation of 6% - 12%,
- operation 20% - 68%,
- drivers' remuneration 14% - 45%,
- remaining costs 12% - 30%.

Based on the cited analysis of the literature, the fig. 1 presents the shares of the three basic cost groups of automotive freight transport enterprises from the perspective of several authors.

For the purpose of achieving the research goal, the data was collected, which was classified into four groups of factors: utility, season, service, economic.

## 3. Research method and object

Tasks carried out at the transport companies that provide services in Poland have been examined. The operation of rolling stock, belonging to 7 different transport companies from the SME sector, involves the implementation of transport tasks in accordance with the needs of customers. The research group includes 24 N1 category motor vehicles, 5 models: Renault Master, Renault Mascott, Citroen Jumper and Fiat Ducato. The study only took into account technical data that had an impact on the aforementioned factors.

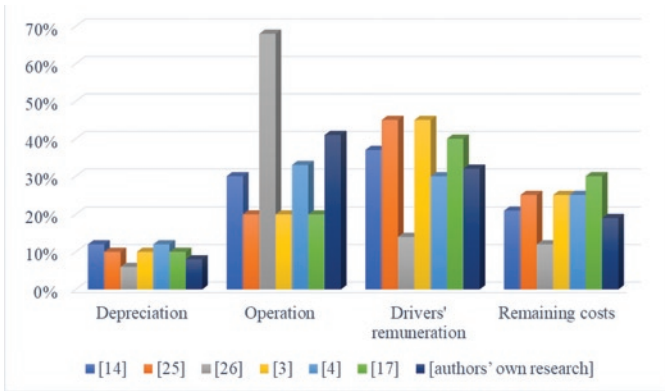


Fig. 1. Comparison of the share of selected cost groups of road freight transport enterprises

Table 2. Set of factors used to modelling maintenance process

	Designation of groups and factors		Units of measurement
	$Y^U$	<b>Group: factors of the motor vehicles operation</b>	
1	$Y_D^U$	number of days of the vehicle use in a month	number
2	$Y_R^U$	monthly vehicle's mileage	kilometres
3	$Y_J^U$	monthly vehicle's driving time	minutes
4	$Y_C^U$	monthly vehicle's working time	minutes
5	$Y_P^U$	average fuel consumption	litres/100 km
6	$Y_M^U$	average daily load weight	kilograms
7	$Y_E^U$	percentage value of the capacity utilization	%
	$Y^K$	<b>Group: time of year</b>	
8	$Y_W^K$	time of year	season 1, season 2, season 3
	$Y^O$	<b>Group: servicing activities of motor vehicles</b>	
9	$Y_P^O$	service fluid refilling	performed, not performed
10	$Y_K^O$	tire service	performed, not performed
11	$Y_H^O$	brakes service	performed, not performed
	$Y^E$	<b>Group: economic factors</b>	
12	$Y_Z^E$	monthly value of orders	PLN
13	$Y_K^E$	monthly operating cost	PLN
14	$Y_M^E$	month revenue from the implementation of transport services	PLN
15	$Y_L^E$	relative unit revenue	PLN/ km
16	$Y_W^E$	relative unit profit	PLN/ km

The following measures of economic efficiency have been defined:

- revenue  $[Y_M^E]$  - expressed as the difference between the monthly value and the monthly operating costs,
- relative revenue  $[Y_L^E]$  - expressed as the ratio of the monthly value of orders to the monthly mileage,
- relative profit  $[Y_W^E]$  - expressed as the ratio of the revenue to the monthly mileage. There are 4 main groups of factors taken into account in the research:
- $Y^U$  - a group of quantities describing the factors of operating motor vehicles: characterizing the manner and intensity of the work performed,
- $Y^K$  - a group of quantities describing the seasons: defining the external conditions in which the vehicle is used,
- $Y^O$  - a group of quantities describing the maintenance of motor vehicles: concerning the maintenance strategy and its effects,
- $Y^E$  - a group of quantities describing economic factors: related to the costs and profitability of carrying out transport tasks.

A set of factors describing the above groups are shown in table 2.

For such defined groups, a real data from one year of vehicles operation (2017) was collected in monthly cycles. These vehicles drove mainly in urban traffic with a few routes outside the city, within this country. The data was obtained from transport orders in the period under review, analyses of the service expertises and interviews with experts (dispatchers, drivers, service technicians, mechanics). The 156 observations of the above factors were made for each vehicle. This way, 3744 data was collected, which was used to model the operation process using a neural network.

#### 4. Neural modelling

When creating the neural network, some of the signals from the table 2 were used, these are:

- quantitative input ones:  $Y_D^U, Y_R^U, Y_J^U, Y_C^U, Y_P^U, Y_M^U, Y_E^U, Y_K^E,$
- quantitative output:  $Y_M^E, Y_L^E, Y_W^E.$

Use the results, among the others [22] of the scientific work, a Multilayer Perceptron and teaching algorithms were used: conjugate gradients; the fastest fall and BFGS (Broyden - Fletcher - Goldfarb - Shanno). The division of the data set into parts in neural modelling was adopted:

- 80% - teaching set used to modify weights,
- 10% - test set for ongoing monitoring of the teaching process,
- 10% - a validation set for assessing the quality of the network after the teaching process.

After determining the input signals, output signals and network parameters, the neural network teaching process was carried out using the Statistica 13.3 computer program. Examples of its results are presented in table 3.

Table 3. Sample results of the neural network teaching process

ID	Network name	Teaching quality	Testing quality	Validation quality	Teaching algorithm	Hidden activation	Output activation
1	MLP 17-11-3	0,796875	0,746498	0,874968	BFGS 28	Exponential	Exponential
2	MLP 17-16-3	0,785931	0,764052	0,874283	BFGS 50	Sinus	Logistic
3	MLP 17-36-3	0,775433	0,804533	0,828288	BFGS 17	Sinus	Exponential
4	MLP 17-30-3	0,762021	0,760954	0,861609	BFGS 23	Sinus	Linear
5	MLP 17-9-3	0,649014	0,612412	0,770544	BFGS 12	Sinus	Tanh
6	MLP 17-6-3	0,755626	0,766049	0,867752	BFGS 51	Linear	Tanh
7	MLP 17-8-3	0,767523	0,742646	0,876113	BFGS 66	Sinus	Tanh
8	MLP 17-31-3	0,776866	0,784677	0,872670	BFGS 36	Linear	Logistic
9	MLP 17-26-3	0,730811	0,783034	0,825576	BFGS 10	Exponential	Sinus
10	MLP 17-9-3	0,807437	0,754784	0,865342	BFGS 38	Logistic	Linear
11	MLP 17-26-3	0,794570	0,754735	0,874439	BFGS 24	Tanh	Logistic
12	MLP 17-3-3	0,796772	0,816948	0,850614	BFGS 52	Logistic	Sinus
13	MLP 17-29-3	0,776284	0,783517	0,874145	BFGS 31	Linear	Logistic
14	MLP 17-19-3	0,813487	0,752890	0,844996	BFGS 45	Logistic	Sinus
15	MLP 17-23-3	0,776775	0,783067	0,873542	BFGS 32	Linear	Logistic
16	MLP 17-17-3	0,838238	0,761414	0,700263	BFGS 64	Tanh	Tanh
17	MLP 17-7-3	0,768890	0,799204	0,819687	BFGS 17	Linear	Exponential
18	MLP 17-6-3	0,780286	0,768095	0,886923	BFGS 28	Logistic	Linear

**5. Validation of the neural network model and calculations results**

The structure of the best neural network took the form of MLP 17-19-3, which means 17 neurons in the input layer, 19 neurons in the hidden layer and 3 neurons in the output layer (fig. 2).




Fig. 2. Structure of the created MLP 17-19-3 network

Since among the input signals, the qualitative input signals have appeared, the total number of neurons at the input represent the sum of all quantitative and qualitative signals, broken down into their individual values. table 4 shows the input signals of the selected neural network.

In the table 3, the MLP 17-19-3 network teaching quality was estimated at around 81% probability of indicating the correct answer, i.e. the adopted measure of economic efficiency. Testing quality - at 75% level and validation quality - at 85%. The BFGS 45 algorithm turned




Fig. 3. Results of MLP 17-19-3 neural network teaching

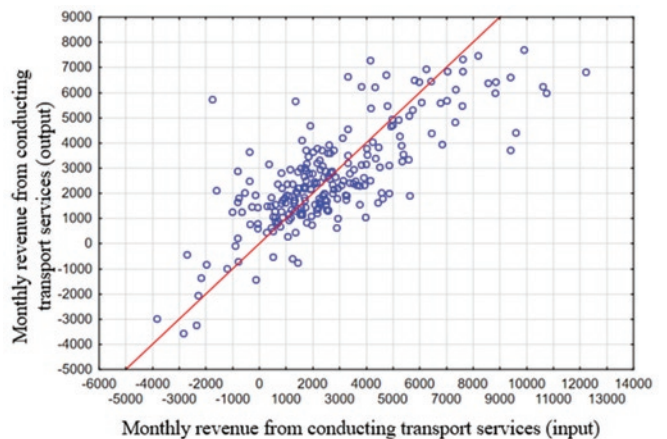


Fig. 4. Dispersion of the dependent variable of the MLP 17-19-3 neural network

Table 4. MLP 17-19-3 neural network individual input signals

	Designation of groups and factors	Units of measurement	ID of the neuron	Value of the neuron
1	$Y_D^U$	number	1	$Y_D^U$
2	$Y_R^U$	kilometers	2	$Y_R^U$
3	$Y_J^U$	minutes	3	$Y_J^U$
4	$Y_C^U$	minutes	4	$Y_C^U$
5	$Y_P^U$	litres/100 km	5	$Y_P^U$
6	$Y_M^U$	kilograms	6	$Y_M^U$
7	$Y_E^U$	%	7	$Y_E^U$
8	$Y_W^K$	season 1, season 2, season 3	8	$Y_W^K$ season 1
			9	$Y_W^K$ season 2
			10	$Y_W^K$ sezaon 3
9	$Y_P^O$	completed, not completed	11	$Y_P^O$ completed
			12	$Y_P^O$ not completed
10	$Y_K^O$	completed, not completed	13	$Y_K^O$ completed
			14	$Y_K^O$ not completed
11	$Y_H^O$	completed, not completed	15	$Y_H^O$ completed
			16	$Y_H^O$ not completed
12	$Y_K^E$	PLN	17	$Y_K^E$

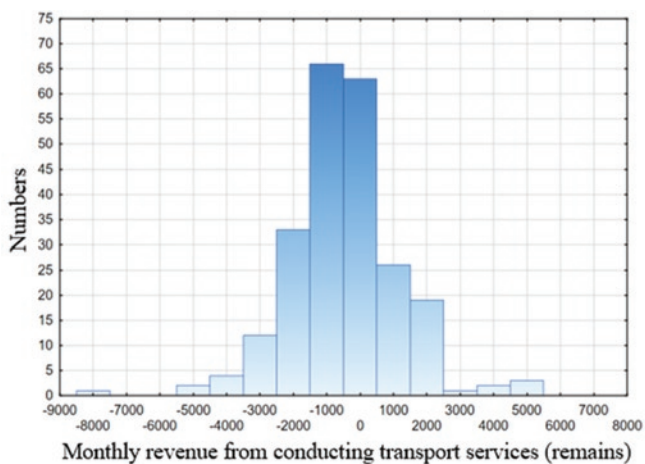


Fig. 5. Distribution of the residues of MLP 17-19-3 neural network

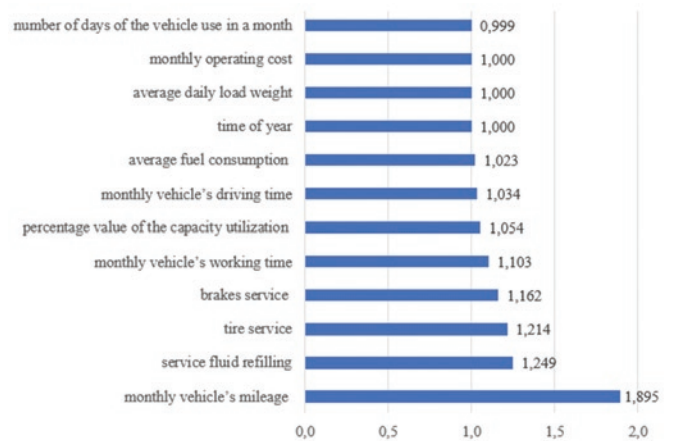


Fig. 6. Global sensitivity analysis for the MLP 17-19-3 neural network

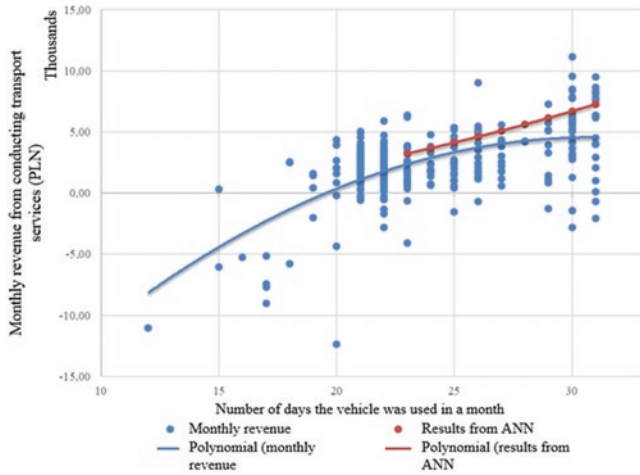


Fig. 7. Monthly revenue in relation to the number of days of the vehicle's operation




Fig. 9. Relative unit profit in respect to the number of days of operation of the vehicle




Fig. 11. Relative unit revenue in relation to the number of days of operation of the vehicle in respect to  $Y^k$

out to be the best teaching algorithm. The positive result of teaching the neural network is demonstrated, by the teaching graph (fig. 3). It shows that the best network structure was found in the 43-rd cycle; the share of incorrect answers was 19% and the error was estimated at 0.002. Also the course of the dispersion changes, shown in fig. 4, indicates a positive outcome of teaching the network.

The results of the calculations presented in fig. 4 show the dispersion between the forecasted revenue value (the result of the calculation in the network during teaching) and its actual value. The visible gathering of the dispersion value around zero is a good result of the model calculations.

The histogram presented in fig. 5 (distribution of residues, i.e. differences between the output variable and its prediction) shows

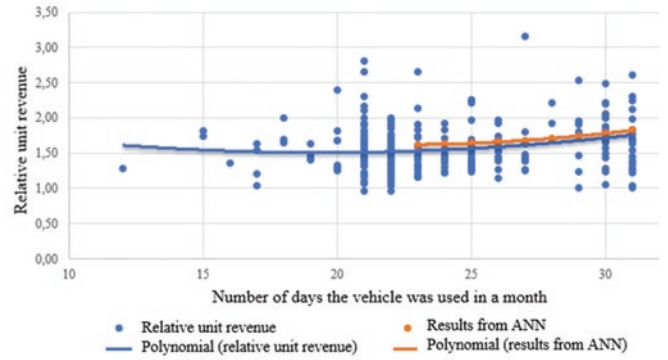


Fig. 8. Relative unit revenue in relation to the number of days of the vehicle's operation




Fig. 10. Relative unit profit in relation to the number of days of operation of the vehicle in respect to  $Y^k$

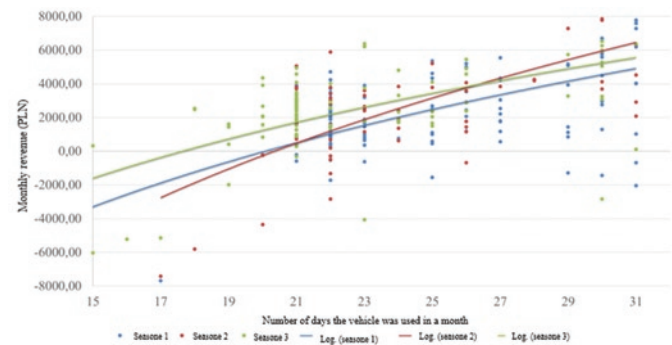


Fig. 12. Monthly revenue in relation to the number of days of operation of the vehicle in respect to  $Y^k$

the number of results of the scatter calculation near zero, which also means a high level of reproducing of the output signals.

In the next stage, a sensitivity analysis was carried out, which involved checking how the network error behaves when input signals are modified. In this calculation, the input signal values are replaced by the average of this signal from the teaching set. After inputting such modified data, the network error was checked. If the error has increased significantly, it means that the network is very sensitive to the signal.

The global sensitivity analysis reflects the impact of individual network input variables on the output signals (fig. 6). These calculations have shown that the greatest impact on the output signals of the neural network have: the monthly number of days of the vehicle's operation, the cost of operation, load weight and time of year.

Based on the selected neural network and the data collected for the neural network teaching process, the trends of changes in the value of efficiency measures are shown, namely: monthly revenue,

Table 5. Example results of the calculations of revenue, unit relative income and unit relative profit for a data set not used in the teaching process

$P_Y^X$	$Y_D^U$	$Y_R^U$	$Y_J^U$	$Y_C^U$	$Y_P^U$	$Y_M^U$	$Y_E^U$	$Y_K^E$	$Y_W^K$	$Y_P^O$	$Y_K^O$	$Y_H^O$	$Y_M^E$	$Y_L^E$	$Y_W^E$
1	30	11360	425	480	15	1661	1,33	12873,13	season 2	yes	yes	yes	5976,87	1,66	0,53
2	31	13331	516	553	15	1771	1,61	15669,06	season 2	yes	yes	yes	2920,94	1,39	0,22
3	24	10127	422	454	15	1408	1,14	13172,67	season 2	yes	yes	yes	1787,33	1,48	0,18
4	30	13750	516	581	15	1887	1,45	16232,06	season 2	yes	yes	yes	9537,95	1,87	0,69
5	30	9470	350	427	15	1697	1,31	14113,56	season 2	yes	yes	yes	3686,44	1,88	0,39
6	28	10527	376	442	15	1556	1,64	16041,24	season 2	yes	yes	yes	4178,76	1,92	0,40
7	17	10700	684	784	15	1588	1,22	20263,87	season 2	yes	yes	yes	-7413,87	1,20	-0,69
8	31	16362	528	602	15	1765	1,36	19235,94	season 2	yes	yes	yes	4514,06	1,45	0,28
9	17	10700	684	784	15	1349	1,23	20120,94	season 2	yes	yes	yes	-9020,94	1,04	-0,84
10	21	7824	447	484	13	743	0,99	9727,43	season 2	yes	yes	yes	722,57	1,34	0,09
11	21	9632	459	491	14	1114	1,11	11636,10	season 2	yes	yes	yes	1593,90	1,37	0,17
12	23	10560	515	635	14	1190	1,04	11430,36	season 2	yes	yes	yes	3319,64	1,40	0,31
13	22	6990	350	430	14	1162	1,01	9105,71	season 2	yes	yes	yes	3794,29	1,85	0,54
14	21	8297	395	459	14	1263	1,05	10928,23	season 2	yes	yes	yes	1541,78	1,50	0,19
15	21	9090	433	497	14	1036	1,04	10968,52	season 2	yes	yes	yes	1881,48	1,41	0,21
16	21	8000	419	520	14	771	1,03	9847,90	season 2	yes	yes	yes	952,10	1,35	0,12
17	31	11760	380	445	15	1454	1,32	15814,58	season 1	yes	yes	yes	4005,42	1,69	0,34
18	26	8600	331	378	15	1561	1,25	11779,84	season 1	yes	yes	no	5200,16	1,97	0,60
19	24	10570	441	538	15	1621	1,32	14242,71	season 1	yes	yes	yes	757,29	1,42	0,07
20	25	10980	440	503	15	1686	1,37	13236,73	season 1	yes	yes	no	5363,27	1,69	0,49
21	31	13230	471	552	15	1802	1,39	15843,46	season 1	yes	yes	yes	8356,54	1,83	0,63
22	30	11520	384	472	15	1620	1,25	16784,69	season 1	yes	yes	yes	2965,31	1,71	0,26
23	31	14500	468	493	15	1642	1,26	16733,81	season 1	yes	yes	yes	1016,19	1,22	0,07
24	31	14400	465	502	15	1513	1,16	15500,69	season 1	yes	yes	yes	8099,31	1,64	0,56
25	22	11290	514	571	15	1563	1,20	12614,45	season 1	yes	yes	yes	865,55	1,19	0,08
26	30	14930	498	603	15	1645	1,73	16990,02	season 1	yes	yes	yes	4509,98	1,44	0,30
27	31	17810	575	613	15	1558	1,64	19222,32	season 1	yes	yes	yes	-672,32	1,04	-0,04
28	30	12860	429	530	15	1645	1,73	17773,67	season 1	yes	yes	yes	5766,33	1,83	0,45
29	30	17040	569	674	15	1807	1,39	19713,65	season 1	yes	yes	yes	1286,35	1,23	0,08
30	12	6850	571	663	15	1779	1,37	19805,28	season 1	yes	yes	yes	-11055,28	1,28	-1,61
31	31	17980	580	618	15	1584	1,22	20049,37	season 1	yes	yes	yes	-2049,37	1,00	-0,11
32	25	14400	576	680	15	1596	1,45	14674,60	season 1	yes	yes	yes	4325,40	1,32	0,30
33	31	10936	423	488	15	1597	1,42	15795,00	season 3	yes	yes	yes	5475,83	2,05	0,50
34	30	10304	405	466	15	1588	1,38	14079,57	season 3	yes	yes	yes	4563,86	1,77	0,44
35	29	8372	358	413	15	1679	1,41	12553,19	season 3	no	no	no	3348,62	1,94	0,40
36	26	11752	503	598	15	1536	1,34	13012,55	season 3	yes	yes	yes	2188,21	1,33	0,19
37	26	10224	430	531	15	1430	1,30	13012,55	season 3	yes	yes	yes	3282,31	1,53	0,32
38	25	11422	472	548	15	1609	1,39	15104,38	season 3	yes	yes	yes	2220,28	1,56	0,19
39	25	8985	389	486	15	1473	1,34	12577,23	season 3	yes	yes	yes	1037,22	1,54	0,12
40	24	9015	391	488	15	1476	1,34	12564,77	season 3	no	no	no	1176,01	1,54	0,13
41	23	10850	435	500	15	1614	1,39	14725,20	season 3	no	no	no	3184,18	1,68	0,29
42	22	8902	441	524	14	1101	1,08	10680,49	season 3	no	no	no	1885,16	1,45	0,21
43	21	8784	435	523	14	1112	1,09	10635,87	season 3	no	no	no	2458,52	1,46	0,28
44	20	8761	434	523	14	1112	1,09	10628,81	season 3	no	no	no	1839,10	1,47	0,21
45	23	11580	475	547	15	1646	1,40	15622,78	season 3	no	no	no	2371,98	1,57	0,20
46	21	9126	434	518	14	1158	1,15	11411,48	season 3	no	no	no	1562,54	1,46	0,17
47	22	8903	437	530	14	1066	1,10	10670,73	season 3	no	no	no	1702,55	1,43	0,19
48	24	9126	409	502	15	1461	1,24	12763,30	season 3	yes	yes	yes	801,64	1,47	0,09

relative unit revenue and relative unit profit in respect to the number of days of vehicle operation (fig. 7, fig. 8, fig. 9).

The analysis conducted also shows that the selected network correctly reproduces the selected measures of economic efficiency. In order to carry out a detailed analysis of the impact of this factor on the output signal, the impact of the time of year on the values of efficiency

measures in relation to the number of days of the vehicle operation was extracted (fig. 10, fig. 11, fig. 12).

Based on the interview with vehicles' drivers, the time of year was determined as the general conditions for meeting the orders, as well as driving comfort and safety:

- season 1 is assigned to months: May, June, July, August,
- season 2: March, April, September, October,

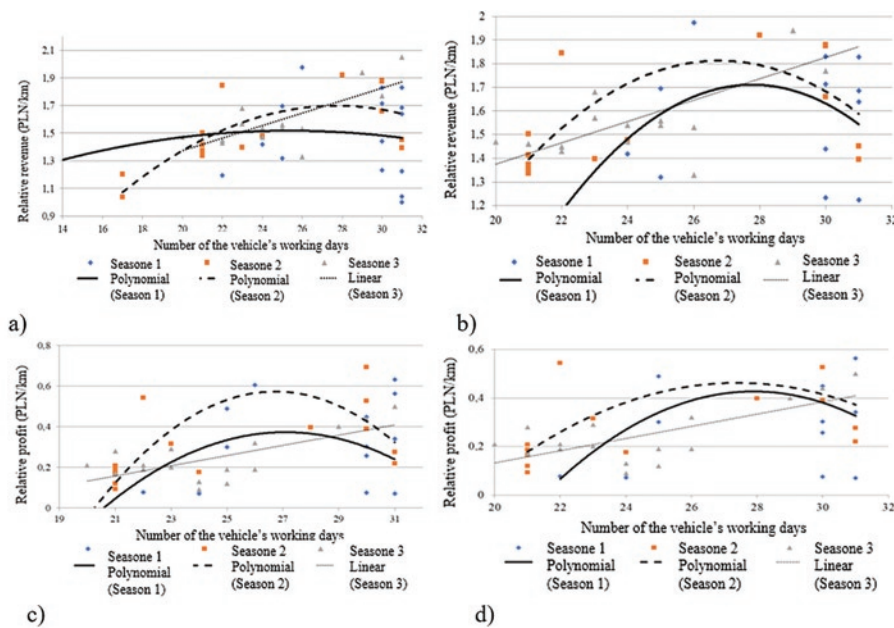


Fig. 13. Results of calculations the revenue and relative profit as a function of the number of days of the vehicle's work

- season 3: January, February, November, December.

The research showed that the highest values of efficiency measures are achieved during the operation of vans and fulfilling orders during season 3, and the lowest during season 1. This is confirmed by the fact of seasonality in providing transport services. Bad weather conditions determining the winter season is the time of increased use of vehicles due to the growing demand for services (season 3), with reduced supply of them. Good weather conditions are observed in the summer season, but then the demand for transport services decreases (season 1). The supply of services in the analyzed sector in this period is higher than the demand for services.

The verification of the proposed method was carried out based on the results of subsequent calculations made after inputting in the neural network a data not used in the teaching process. Examples of final results are presented in table 5.

Based on the global sensitivity analysis and the results obtained (table 5), it can be concluded that revenue increases with the increase in the number of days the vehicle works. Relative revenue and relative profit are calculated below in two ways: taking into account all variants of orders together with those generating a loss and taking into account only variants generating profit from order execution.

## References

1. Aleksandrowicz P, Żółtowski B. Vehicle repair costs calculation systems. Polish Association for Knowledge Management. Warszawa: BEL Studio sp. z o.o., 2010.
2. Andrzejczak K, Młyńczak M, Selech J. Poisson-distributed failures in the predicting of the cost of corrective maintenance. *Eksploracja i Niezawodność - Maintenance and Reliability* 2018; 20 (4): 602-609, <https://doi.org/10.17531/ein.2018.4.11>.
3. Biesok G. *Logistyka Usług*. Warszawa: CeDeWu, 2013.
4. Bronk H. Cechy i układ kosztów w transporcie umożliwiające podejmowanie decyzji. *Koszty i ceny w transporcie. Pomiar analiza*. Szczecin: Zeszyty naukowe 813, 2014; 21 - 38.
5. Chen X, Xiao L, Zhang X, Xiao W, Li J. An integrated model of production scheduling and maintenance planning under imperfect preventive maintenance. *Eksploracja i Niezawodność - Maintenance and Reliability* 2015; 17 (1): 70-79, <https://doi.org/10.17531/ein.2015.1.10>.
6. Chłopek Z, Bebkiewicz K. Model of the structure of motor vehicles for the criterion of the technical level on account of pollutant emission. *Eksploracja i Niezawodność - Maintenance and Reliability* 2017; 19 (4): 501-507, <https://doi.org/10.17531/ein.2017.4.2>.
7. Coupek D, Gulec A, Lechler A, Verl A. Selective rotor assembly using fuzzy logic in the production of electric drives. *Conference on Intelligent Computation in Manufacturing Engineering*, 2014, <https://doi.org/10.1016/j.procir.2015.06.074>.
8. Gohari A, Matori NA, Yusof K W, Toloue I, Sholagberu A T. The effect of fuel price increase on transport cost of container transport vehicles.

The studies have also shown that the season is also an important factor influencing the relationship between the number of working days and revenue or profit. The season determines the rate of increase in relative income and relative profit. This rate is high in the range of 10-22 days of vehicle work and becomes moderate in the range of 23-25 days of work per month. However, increasing the number of working days above 26-27 no longer results in an increase in benefits. The results presented in fig. 13c) confirm that in order to achieve relative profit vehicles should be used not less than 20 days a month, while the analysis of predictions without taking into account orders bringing losses (fig. 13d) confirms that it is over 21 days of work for season 2 and 22 days for season 1.

## 6. Summary

The results obtained and presented in the article allowed the statements that the adopted measures of economic efficiency have illustrated the impact of the number of vehicles' working days on the revenue and profit from transport services, and that the developed model is useful for predicting monthly revenue from transport services.

The results of the calculations provide the basis for the statement that increasing the number of days of the vehicle's work has a limited impact on the revenue growth process in the company. It is observed that positive income values are achieved with the number of working days over 19-20.

Both the number and type of data used in the neural network allowed to achieve high analysis results at the level of 80-90% efficiency.

The calculations results obtained results showed the specific features of the impact of the number of working days on the revenue in a transport company. The increase in the number of working days is conducive to increased revenue in a limited way, and this restriction depends on the season of the year.

The neural network model developed supports decision making in the implementation of transport processes, taking into account the economic efficiency of the motor vehicle operation process. Thus, the obtained results showed the usefulness of the adopted measures of economic efficiency and the model built to predict the economic results of the company's transport activities.



- International Journal of GEOMATE 2018; 15: 174-181, <https://doi.org/10.21660/2018.50.30814>.
9. Himanen V, Nijkamp P, Reggiani A. Neural networks in transport applications. Ashgate 1998. Reissued 2018 by Routledge, <https://doi.org/10.4324/9780429445286>.
  10. Józwiak A. Application of Kohonen's Network in Logistics. *Gospodarka Materiałowa i Logistyka* 2017; 5: 258-271.
  11. Kijek M, Brzeziński M, Gontarczyk M, Rykała Ł, Zolkowski J. Fuzzy Modeling of Evaluation Logistic Systems. *Transport Means* 2017; 2: 377-382.
  12. Kleiner F, Friedrich H E. Development of a Transport Application based Cost Model for the assessment of future commercial vehicle concepts. Geneva: European Battery, Hybrid and Fuel Cell Electric Vehicle Congress, 2017.
  13. Kowalski M, Magott J, Nowakowski T, Werbińska-Wojciechowska T. Analysis of transportation system with the use of Petri nets. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2011; 1 (49): 48-62.
  14. Koźlak A. *Ekonomika transportu. Teoria i praktyka*. Gdańsk: Wydawnictwo Uniwersytetu Gdańskiego, 2010.
  15. Mendyk E. *Ekonomika transportu*. Poznań: Wyższa Szkoła Logistyki, 2009.
  16. Niewczas A, Rymarz J, Debicka E. Stages of operating vehicles with respect to operational efficiency using city buses as an example. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2019; 21 (1): 21-27, <https://doi.org/10.17531/ein.2019.1.3>.
  17. Oziemiński S. *Efektywność eksploatacji maszyn. Podstawy techniczno - ekonomiczne*. Radom: Biblioteka problemów eksploatacji, 1999.
  18. Prochowski L. Evaluation of the process of mileage growth during the operation of motor trucks, in several categories of engine cubic capacity. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2018; 20 (3): 359-370, <https://doi.org/10.17531/ein.2018.3.3>.
  19. Raporty z Internetu Głównego Inspektoratu Transportu Drogowego.
  20. Rudyk T, Szczepański E, Jacyna M. Safety factor in the sustainable fleet management model. *Archives of Transport* 2019; 49: 103-114, <https://doi.org/10.5604/01.3001.0013.2780>.
  21. Świdorski A, Borucka A, Jacyna-Gołda I, Szczepański E. Wear of brake system components in various operating conditions of vehicle in the transport company. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2019; 21 (1): 1-9, <https://doi.org/10.17531/ein.2019.1.1>.
  22. Świdorski A, Józwiak A, Jachimowski R. Operational quality measures of vehicles applied for the transport services evaluation using artificial neural networks. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2018; 20 (2): 292-299, <https://doi.org/10.17531/ein.2018.2.16>.
  23. Świdorski A. Studies and quality assurance neural modelling of the technical transport means. *Archive of Transport*. Polish Academy of Sciences Committee of Transport 2009; 21 (3-4).
  24. Teodorovic D, Vukadinovic K. *Traffic Control and Transport Planning: A Fuzzy Sets and Neural Networks Approach*. Springer Science+Business Media 2012.
  25. Urbanyi-Popiołek I. *Ekonomiczne i organizacyjne aspekty transportu*. Bydgoszcz: Wyższa Szkoła Gospodarki, 2013.
  26. Witkowski K, Tanona K. Analiza kosztów transportu drogowego. *Logistyka* 2013; 5: 411 - 416.
  27. Zał. nr 2. do U. z dnia 20 czerwca 1997 r. Prawo o ruchu drogowym.

---

**Arkadiusz JÓŻWIAK****Paulina OWCZAREK**

Faculty of the Security, Logistics and Management  
Military University of Technology  
ul. gen. Sylwestra Kaliskiego 2, 00-908 Warsaw 46, Poland

**Leon PROCHOWSKI**

Faculty of Mechanical Engineering  
Military University of Technology  
ul. gen. Sylwestra Kaliskiego 2, 00-908 Warsaw 46, Poland

**Andrzej ŚWIDERSKI**

Motor Transport Institute  
ul. Jagiellońska 80, 03-301 Warsaw, Poland

E-mails: [arkadiusz.jozwiak@wat.edu.pl](mailto:arkadiusz.jozwiak@wat.edu.pl), [paulina.owczarek@wat.edu.pl](mailto:paulina.owczarek@wat.edu.pl),  
[leon.prochowski@wat.edu.pl](mailto:leon.prochowski@wat.edu.pl), [andrzej.swiderski@its.waw.pl](mailto:andrzej.swiderski@its.waw.pl)

---

### **kpt. dr inż. Arkadiusz Jóźwiak**

Wydział Bezpieczeństwa, Logistyki i Zarządzania  
Wojskowa Akademia Techniczna  
ul. gen. Sylwestra Kaliskiego 2, 00-908 Warszawa 46, Polska  
e-mail: arkadiusz.jozwiak@wat.edu.pl

### **mgr inż. Paulina Owczarek**

Wydział Bezpieczeństwa, Logistyki i Zarządzania  
Wojskowa Akademia Techniczna  
ul. gen. Sylwestra Kaliskiego 2, 00-908 Warszawa 46, Polska  
e-mail: paulina.owczarek@wat.edu.pl

### **prof. dr hab. inż. Leon Prochowski**

Wydział Inżynierii Mechanicznej  
Wojskowa Akademia Techniczna  
ul. gen. Sylwestra Kaliskiego 2, 00-908 Warszawa 46, Polska  
e-mail: leon.prochowski@wat.edu.pl

### **dr hab. inż. Andrzej Świderski, prof. ITS**

Instytut Transportu Samochodowego  
ul. Jagiellońska 80, 03-301 Warszawa  
e-mail: andrzej.swiderski@its.waw.pl

## **Badanie wpływu czasu wykorzystania samochodów kategorii N1 na efektywność ekonomiczną ich eksploatacji**

**Słowa kluczowe:** eksploatacja samochodów, pojazdy samochodowe kategorii N1, efektywność ekonomiczna, sieci neuronowe

**Streszczenie:** Rozważa się efektywność eksploatacji samochodów ciężarowych o DMC < 3,5 tony. Są to pojazdy należące do kategorii N1 (według Dyrektywy 2007/46/WE) zwykle nazywane samochodami dostawczymi. Do prowadzonej analizy efektywności wykorzystano wyniki obserwacji z realizacji zleceń przewozowych w 7 firmach transportowych z sektora MŚP. Grupa badawcza objęła 24 pojazdy, które wykonywały zadania transportowe w strefie miejskiej i w najbliższym otoczeniu miasta. Informacje gromadzono w cyklach miesięcznych.

Podczas analizy efektywności ekonomicznej zastosowano kilka miar przychodu (bezwzględny i względny). Obliczenia prowadzono przy wykorzystaniu modelu procesu eksploatacji pojazdów w postaci sieci neuronowej, w której brano pod uwagę zbiór 12 zmiennych wejściowych i 3 zmienne wyjściowe. Stosując program komputerowy Statistica 13.3 oraz zdefiniowanie grupy i czynniki opisujące proces realizacji poszczególnych zadań transportowych, opracowany model sieci neuronowej umożliwił poszukiwanie wpływu wybranych czynników eksploatacyjnych na efektywność ekonomiczną samochodów kategorii N1.

Przeprowadzone obliczenia pokazały istotny wpływ liczby dni pracy pojazdów w miesiącu, masę ładunku, a także porę roku. Uzyskane wyniki obliczeń pokazały specyficzne cechy wpływu liczby dni pracy na przychód w firmie transportowej. Wzrost liczby dni pracy sprzyja wzrostowi przychodu w sposób ograniczony, a to ograniczenie zależy m.in. od pory roku.

## 1. Wstęp

Specyfika użytkowania pojazdów samochodowych kategorii N1 stale wzbudza wiele kontrowersji, a w obszarze uwarunkowań prawnych nadal pojawia się szereg niejasności, co wpływa na znikomą literaturę w tym obszarze. W każdym miesiącu pojawiają się nowe informacje dotyczące statystyk Głównego Inspektoratu Transportu Drogowego o wynikach kontroli pojazdów samochodowych kategorii N1. Od kilku lat udział procentowy pojazdów z ładunkiem przekraczającym ich dopuszczalną ładowność w stosunku do skontrolowanych pojazdów kategorii N1 utrzymuje się na poziomie średnio 93% (tabela 1) [19]. Faktem jest, że Inspekcja Transportu Drogowego kontroluje zwykle pojazdy ciężarowe powyżej 3,5 tony, natomiast pojazdy kategorii N1 tylko wtedy, kiedy uzna, że istnieje wyraźne podejrzenie popełnienia konkretnego wykroczenia. Liczba kontrolowanych pojazdów jest znikoma, nie mniej jednak wskaźnik udziału procentowego pojazdów z ładunkiem przekraczającym ich dopuszczalną ładowność do 3,5 tony wskazywać może na istnienie złożonego problemu, którego poddać należy szczegółowej analizie.

Tabela 1. Udział procentowy pojazdów z ładunkiem przekraczającym ich dopuszczalną ładowność w stosunku do skontrolowanych pojazdów kategorii N1 [19]

	2014 r.	2015 r.	2016 r.	2017 r.
Liczba wszystkich pojazdów o DMC do 3,5 t	2 399 323	2 447 764	2 515 751	2 574 312
Liczba skontrolowanych pojazdów o DMC do 3,5 t	6 685	6 507	7 594	10 048
Liczba wystawionych mandatów pojazdom z ładunkiem przekraczającym ich dopuszczalną ładowność	6 135	6 172	6 172	9 396
Udział procentowy	92%	95%	92%	94%

Zasadne staje się więc zainteresowanie tematyką zwiększania zysków z eksploatacji pojazdów samochodowych kategorii N1. Odwzorowanie i uproszczenie zjawisk rzeczywistych w postaci modelu staje się ważnym elementem w poszukiwaniu skutecznych metod opisu problemów i zakłóceń w procesie użytkowania i obsługi pojazdów samochodowych. W rezultacie ułatwia to znalezienie sposobów na zwiększanie efektywności ekonomicznej przedsiębiorstw transportowych.

W artykule podmiotem badań jest efektywność eksploatacji samochodów kategorii N1, które zgodnie z [27] określa się jako pojazdy zaprojektowane i wykonane do przewozu ładunków i mające maksymalną masę całkowitą nieprzekraczającą 3,5 tony (DMC do 3,5 t). W praktyce tego typu pojazdy określa się pojęciem pojazdy dostawcze, dlatego w dalszej części artykułu pojęcie to stosowane będzie zamiennie.

Planowanie i realizacja procesu eksploatacji pojazdów samochodowych w złożonym systemie transportowym związane jest z rozwiązywaniem wielokryterialnych problemów decyzyjnych, które skupiają się m.in. na minimalizacji kosztów i osiągnięciu maksymalnego zysku. Zagadnienie to dotyczy problematyki dwóch podstawowych elementów procesu

eksploatacji, tj. użytkowania i obsługiwanego pojazdów samochodowych. Efektywne wykorzystanie środków transportu w każdym przedsiębiorstwie jest jednym z głównych sposobów na osiągnięcie przewagi konkurencyjnej.

Szeroko prowadzone analizy procesu eksploatacji pojazdów samochodowych dotyczą najczęściej minimalizowania kosztów związanych z ich użytkowaniem oraz zapewniania maksymalnej niezawodności systemu transportowego, a także wpływu użytkowania pojazdów na środowisko naturalne [21], czy też aspektu bezpieczeństwa [20]. Natomiast ocena intensywności eksploatacji pojazdów samochodowych jest prowadzona z uwzględnieniem m.in. wartości przebiegu, pojemności silnika, wieku pojazdu [18], kosztów napraw, przychodów [16], gotowości technicznej, intensywności użytkowania pojazdów samochodowych [6]. Ze względu na losowy charakter awarii pojazdów dla utrzymania efektywnej i bezpiecznej ich eksploatacji niezbędna okazuje się wiedza dotycząca procesów stochastycznych [2].

Modelowanie i ocena tak złożonych procesów na podstawie klasycznych modeli matematycznych oraz techniki teorii niezawodności może być trudna do przeprowadzenia i nie przynosić oczekiwanych rezultatów ze względu na dużą liczbę danych ilościowych i jakościowych oraz ze względu na dynamicznie zmieniające się uwarunkowania systemu eksploatacji pojazdów. W takim przypadku proponowane są inne metody obliczeniowe, np. modele wykorzystujące procesy Markowa lub niezawodnościowe diagramy fazowe, model sieci Petriego lub procesy symulacji Monte Carlo [13], algorytm odpornościowej selekcji klonalnej [5].

Biorąc pod uwagę stopień złożoności badanego problemu oraz coraz szersze wykorzystanie metod sztucznej inteligencji do rozwiązywania tego typu zadań, celem niniejszej pracy staje się ocena efektywności ekonomicznej przedsiębiorstw transportowych przy wykorzystaniu sieci neuronowej. Ocena jest ukierunkowana na firmy transportowe, funkcjonujące na rzecz transportu drobnicowego w obszarach miejskich i podmiejskich. W pracy wykorzystano kilka miar przychodu w działalności transportowej opisane w dalszej części pracy.

Wszędzie tam, gdzie nie ma podstaw do aproksymacji liniowej występujących zjawisk i procesów, zwykle przy rozwiązywaniu trudnych i kłopotliwych zagadnień oceny m.in. efektywności eksploatacji samochodów, racjonalnym może być odwołanie się do sieci neuronowych lub innych algorytmów sztucznej inteligencji (a więc modeli, które odwzorowują zależności nieliniowe) [7], [9], [10], [24]. Sztuczne sieci neuronowe są jedną z technik wykorzystywaną przez sztuczną inteligencję. Istnieją również inne zastosowania sztucznej inteligencji w transporcie. Dla przykładu: do oceny zapewnienia jakości środków transportu, do optymalizacji tras przejazdu [11], czy do oceny zarządzania konfiguracją usług transportowych [23].

## **2. Analiza kosztów przedsiębiorstwa transportowego z taborem pojazdów samochodowych kategorii N1**


W dalszym ciągu w pierwszej kolejności wyboru dostawcy usług transportowych wybiera się poprzez kryterium minimalnej ceny. Duża konkurencja i stale rosnące wymagania rynku transportowego zmuszają przewoźników do nieustannego poszukiwania metod minimalizowania kosztów przedsiębiorstwa przewozowego. Generowanie przychodów w firmach transportowych opiera się przede wszystkim na intensywności użytkowania pojazdów. Z reguły są one proporcjonalne do liczby przejechanych kilometrów, masy ładunku czy przepracowanych godzin. Intensywne użytkowanie pojazdów generuje nie tylko wzrost przychodów, ale też kosztów, dlatego niezmiernie ważne jest dokonanie ich szczegółowej analizy.

W przedsiębiorstwach, także transportowych, jedną z najczęściej stosowanych metod podziału kosztów jest ich układ rodzajowy, zawierający 7 grup, które stanowią jednocześnie nazwy kont syntetycznych: amortyzacja, zużycie materiałów i energii, usługi obce, podatki i opłaty, wynagrodzenia, ubezpieczenia społeczne i inne świadczenia, pozostałe koszty (rodzajowe).

Wg wielu publikacji koszty usług obcych stanowią największy udział procentowy w stosunku do wszystkich kosztów przedsiębiorstwa transportowego [15]. W niniejszym opracowaniu podmiotem badań są *mikro, małe i średnie* przedsiębiorstwa (mikro i MŚP), dlatego struktura kosztów będzie nieco różniła się od ogólnej klasyfikacji kosztów rodzajowych przedsiębiorstw. Powodem tego może być chociażby fakt posiadania przez mikro i MŚP jedynie własnego, nieleasingowanego już taboru, który usługi przewozowe świadczy bezpośrednio bez udziału firm outsourcingowych. Zagadnienia związane szczegółowo z kosztami przedsiębiorstw transportu samochodowego ładunków są przedmiotem zainteresowań wielu autorów [1], [4], [8], [12], [15], [26] którzy najczęściej sprowadzają je do czterech podstawowych grup rodzajowych i określają ich wartości procentowe w stosunku do pozostałych kosztów:

- amortyzacja 6% – 12%,
- eksploatacja 20% – 68%,
- wynagrodzenie kierowców 14% – 45 %,
- pozostałe koszty 12% – 30 %.

Na podstawie przytoczonej analizy literatury, na rys. 1 przedstawiono udziały trzech podstawowych grup kosztów przedsiębiorstw samochodowego transportu ładunków z perspektywy kilku autorów.



Rys. 1. Porównanie udziału wybranych grup kosztów przedsiębiorstw samochodowego transportu ładunków

Na potrzeby osiągnięcia celu badawczego zebrano dane, które sklasyfikowano w czterech grupach czynników: użytkowe, pory roku, obsługowe, ekonomiczne.

### 3. Metoda i obiekt badań

Badaniom poddano zadania wykonywane w firmach transportowych, które realizują usługi na terenie Polski. Praca taboru, należącego do 7 różnych firm transportowych z sektora MŚP polega na realizacji zadań transportowych zgodnie z zapotrzebowaniem klientów. Grupa badawcza obejmuje 24 pojazdy samochodowe kategorii N1, 5 modeli: Renault Master, Renault Mascott, Citroen Jumper i Fiat Ducato. W badaniach brano pod uwagę jedynie te dane techniczne, które miały wpływ na wymienione wcześniej czynniki.

Zdefiniowano następujące miary efektywności ekonomicznej:

- przychód [ $Y_M^E$ ] – wyrażony jako różnica miesięcznej wartości i miesięcznych kosztów eksploatacji,
- przychód względny  $Y_L^E$  – wyrażony jako stosunek miesięcznej wartości zleceń do przebiegu miesięcznego,
- zysk względny  $Y_W^E$  – wyrażony jako stosunek dochodu do przebiegu miesięcznego.

Zdefiniowano 4 główne grupy czynników branych pod uwagę w badaniach:

- $Y^U$  - grupa wielkości opisujących czynniki użytkowania pojazdów samochodowych: charakteryzujące sposób i intensywność wykonywanej pracy,
- $Y^K$  - grupa wielkości opisujących pory roku: definiujące warunki zewnętrzne w jakich użytkowany jest pojazd,
- $Y^O$  - grupa wielkości opisujących czynności obsługowe pojazdów samochodowych: dotyczące prowadzonej strategii obsługowej oraz jej efektów,
- $Y^E$  - grupa wielkości opisujących czynniki ekonomiczne: związane z kosztami i rentownością realizacji zadań przewozowych.

Zbiór czynników opisujących ww. grupy przedstawiono w tabeli 2.

Tabela 2. Zbiór czynników wykorzystanych podczas modelowania procesu eksploatacji

	Oznaczenia grup i czynników		Jednostki miary
	$Y^U$	<b>Grupa: czynniki użytkowania pojazdów samochodowych</b>	
1	$Y_D^U$	liczba dni użytkowania pojazdu w miesiącu	liczba
2	$Y_R^U$	miesięczny przebieg pojazdu	kilometry
3	$Y_J^U$	miesięczny czas jazdy pojazdu	minuty
4	$Y_C^U$	miesięczny czas pracy pojazdu	minuty
5	$Y_P^U$	średnie zużycie paliwa	litry/100 km
6	$Y_M^U$	średnia dzienna masa ładunku	kilogramy
7	$Y_E^U$	wartość procentowa wykorzystania ładowności	%
	$Y^K$	<b>Grupa: pora roku</b>	
8	$Y_W^K$	pora roku	sezon 1, sezon 2, sezon 3
	$Y^O$	<b>Grupa: czynności obsługowe pojazdów samochodowych</b>	
9	$Y_P^O$	uzupełnianie płynów	wykonano, nie wykonano
10	$Y_K^O$	serwis ogumienia	wykonano, nie wykonano
11	$Y_H^O$	serwis hamulców	wykonano, nie wykonano

	Oznaczenia grup i czynników		Jednostki miary
	$y^E$	Grupa: czynniki ekonomiczne	
12	$Y_Z^E$	miesięczna wartość zleceń	zł
13	$Y_K^E$	miesięczny koszt eksploatacji	zł
14	$Y_M^E$	miesięczny przychód z realizacji usług przewozowych	zł
15	$Y_L^E$	względny jednostkowy przychód	zł/km
16	$Y_W^E$	względny zysk jednostkowy	zł/km

Dla tak zdefiniowanych grup zebrano rzeczywiste dane z jednego roku eksploatacji pojazdów (2017) w cyklach miesięcznych. Pojazdy te poruszały się głównie w ruchu miejskim z pojedynczymi trasami poza miastem na terenie kraju. Dane uzyskano ze zleceń transportowych w badanym okresie, analiz ekspertyz serwisowych i wywiadów z ekspertami (dyspozytorami, kierowcami, serwisantami, mechanikami). Dla każdego pojazdu dokonano 156 obserwacji wymienionych czynników. W taki sposób zebrano 3744 danych, które posłużyły do modelowania procesu eksploatacji z wykorzystaniem sieci neuronowej.

#### 4. Modelowanie neuronowe

Podczas tworzenia sieci neuronowej wykorzystano część sygnałów z tabela 2, są to:

- wejściowe ilościowe:  $Y_D^U, Y_R^U, Y_J^U, Y_C^U, Y_P^U, Y_M^U, Y_E^U, Y_K^E$ ,
- wejściowe jakościowe:  $Y_P^O, Y_K^O, Y_H^O, Y_W^K$ ,
- wyjściowe ilościowe:  $Y_M^E, Y_L^E, Y_W^E$ .

Z wykorzystaniem wyników m.in. [22] pracy naukowej, zastosowano perceptron wielowarstwowy (*Multilayer Perceptron*) i algorytmy uczące: gradientów sprzężonych; najszybszego spadku i BFGS (*Broyden – Fletcher – Goldfarb - Shanno*). W modelowaniu neuronowym przyjęto podział zbioru danych na części:

- 80 % - zbiór uczący wykorzystywany do modyfikacji wag,
- 10 % - zbiór testowy przeznaczony do bieżącego monitorowania procesu uczenia,
- 10 % - zbiór walidacyjny do oceny jakości sieci po zakończeniu procesu uczenia.


Po określeniu sygnałów wejściowych, sygnałów wyjściowych i parametrów sieci, przeprowadzono proces uczenia sieci neuronowej z wykorzystaniem programu komputerowego Statistica 13.3. Przykładowe jego wyniki przedstawiono w tabela 3.

Tabela 3. Przykładowe wyniki procesu uczenia sieci neuronowej

ID	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Aktywacja ukryta	Aktywacja wyjściowa
1	MLP 17-11-3	0,796875	0,746498	0,874968	BFGS 28	Wykładnicza	Wykładnicza
2	MLP 17-16-3	0,785931	0,764052	0,874283	BFGS 50	Sinus	Logistyczna
3	MLP 17-36-3	0,775433	0,804533	0,828288	BFGS 17	Sinus	Wykładnicza
4	MLP 17-30-3	0,762021	0,760954	0,861609	BFGS 23	Sinus	Liniowa
5	MLP 17-9-3	0,649014	0,612412	0,770544	BFGS 12	Sinus	Tanh
6	MLP 17-6-3	0,755626	0,766049	0,867752	BFGS 51	Liniowa	Tanh
7	MLP 17-8-3	0,767523	0,742646	0,876113	BFGS 66	Sinus	Tanh
8	MLP 17-31-3	0,776866	0,784677	0,872670	BFGS 36	Liniowa	Logistyczna
9	MLP 17-26-3	0,730811	0,783034	0,825576	BFGS 10	Wykładnicza	Sinus
10	MLP 17-9-3	0,807437	0,754784	0,865342	BFGS 38	Logistyczna	Liniowa
11	MLP 17-26-3	0,794570	0,754735	0,874439	BFGS 24	Tanh	Logistyczna
12	MLP 17-3-3	0,796772	0,816948	0,850614	BFGS 52	Logistyczna	Sinus
13	MLP 17-29-3	0,776284	0,783517	0,874145	BFGS 31	Liniowa	Logistyczna
14	MLP 17-19-3	0,813487	0,752890	0,844996	BFGS 45	Logistyczna	Sinus
15	MLP 17-23-3	0,776775	0,783067	0,873542	BFGS 32	Liniowa	Logistyczna
16	MLP 17-17-3	0,838238	0,761414	0,700263	BFGS 64	Tanh	Tanh
17	MLP 17-7-3	0,768890	0,799204	0,819687	BFGS 17	Liniowa	Wykładnicza
18	MLP 17-6-3	0,780286	0,768095	0,886923	BFGS 28	Logistyczna	Liniowa

## 5. Walidacja modelu sieci neuronowej i wyniki obliczeń

Struktura najlepszej sieci neuronowej przyjęła postać MLP 17-19-3, co oznacza 17 neuronów w warstwie wejściowej, 19 neuronów w warstwie ukrytej i 3 neurony w warstwie wyjściowej (rys. 2).



Rys. 2. Struktura utworzonej sieci MLP 17-19-3


Ponieważ wśród sygnałów wejściowych, pojawiły się sygnały wejściowe jakościowe, łączna liczba neuronów na wejściu stanowi sumę wszystkich sygnałów ilościowych i jakościowych z podziałem na poszczególne ich wartości. Tabela 4 przedstawia rozpisane sygnały wejściowe wybranej sieci neuronowej.



Tabela 4. Rozpisane sygnały wejściowe sieci neuronowej MLP 17-19-3


	Oznaczenia grup i czynników	Jednostki miary	ID neuronu	Wartość neuronu
1	$Y_D^U$	liczba	1	$Y_D^U$
2	$Y_R^U$	kilometry	2	$Y_R^U$
3	$Y_J^U$	minuty	3	$Y_J^U$
4	$Y_C^U$	minuty	4	$Y_C^U$
5	$Y_P^U$	litry/100 km	5	$Y_P^U$
6	$Y_M^U$	kilogramy	6	$Y_M^U$
7	$Y_E^U$	%	7	$Y_E^U$
8	$Y_W^K$	sezon 1, sezon 2, sezon 3	8	$Y_W^K$ sezon 1
			9	$Y_W^K$ sezon 2
			10	$Y_W^K$ sezon 3
9	$Y_P^O$	wykonano, nie wykonano	11	$Y_P^O$ wykonano
			12	$Y_P^O$ niewykonano
10	$Y_K^O$	wykonano, nie wykonano	13	$Y_K^O$ wykonano
			14	$Y_K^O$ niewykonano
11	$Y_H^O$	wykonano, nie wykonano	15	$Y_H^O$ wykonano
			16	$Y_H^O$ niewykonano
12	$Y_K^E$	zł	17	$Y_K^E$

W tabeli 3 jakość uczenia sieci MLP 17-19-3 została oszacowana na poziomie ok 81% prawdopodobieństwa wskazania poprawnej odpowiedzi, czyli przyjętej miary efektywności ekonomicznej. Jakość testowania - na poziomie 75% i jakość walidacji - na poziomie 85%. Najlepszym algorytmem uczenia okazał się algorytm BFGS 45. O pozytywnym wyniku uczenia sieci neuronowej świadczy m.in. wykres uczenia (rys. 3). Wynika z niego, że najlepszą strukturę sieci odnaleziono w 43 cyklu; udział błędnych odpowiedzi wyniósł 19 %, a błąd został oszacowany na poziomie 0,002.



Rys. 3. Rezultaty uczenia sieci neuronowej MLP 17-19-3


Również przebieg zmian rozrzutu, przedstawiony na rys. 4, wskazuje na pozytywny wynik uczenia sieci.



Rys. 4. Rozrzut zmiennej zależnej sieci neuronowej MLP 17-19-3

Wyniki obliczeń przedstawionych na rys. 4 pokazują rozrzut między wartością prognozowaną przychodu (wynik obliczenia w sieci w trakcie uczenia) a jego rzeczywistą wartością. Widoczne skupienie wartości rozrzutu w pobliżu zera jest dobrym rezultatem obliczeń modelowych.


Histogram, przedstawiony na rys. 5 (rozkład reszt, czyli różnic między zmienną wyjściową i jej predykcją) pokazuje liczbę wyników obliczeń rozrzutu w pobliżu zera, co oznacza także wysoki poziom odwzorowania sygnałów wyjściowych.



Rys. 5. Rozkład reszt sieci neuronowej MLP 17-19-3

W kolejnym etapie, przeprowadzono analizę wrażliwości, która polegała na sprawdzeniu, jak zachowuje się błąd sieci w przypadku gdy modyfikowane są sygnały wejściowe. W tym obliczeniu wartości sygnału wejściowego zastępowane są przez średnią tego sygnału ze zbioru uczącego. Po podaniu tak zmodyfikowanych danych wejściowych sprawdzono błąd sieci. Jeśli błąd wzrósł znacznie, oznacza to, że sieć jest bardzo wrażliwa na dany sygnał.


Globalna analiza wrażliwości odzwierciedla wpływ poszczególnych zmiennych wejściowych sieci na sygnały wyjściowe (rys. 6).



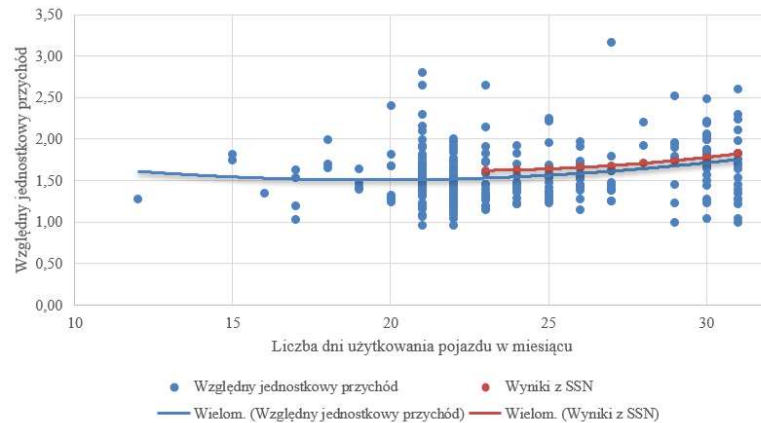
Rys. 6. Globalna analiza wrażliwości dla sieci neuronowej MLP 17-19-3

Obliczenia te pokazały, że największy wpływ na sygnały wyjściowe sieci neuronowej mają: miesięczna liczba dni pracy pojazdu, koszt eksploatacji, masa ładunku i sezon.

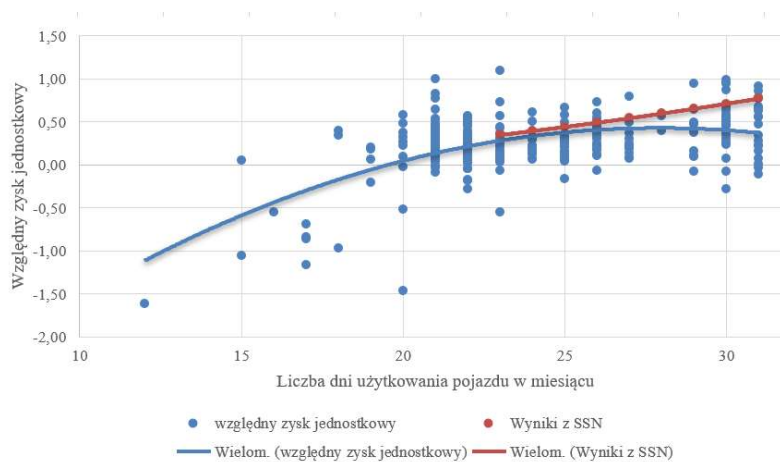
Na podstawie wybranej sieci neuronowej i danych zebranych do procesu uczenia sieci neuronowej pokazano trendy zmian wartości miar efektywności, mianowicie: miesięczny przychód, względny jednostkowy przychód i względny zysk jednostkowy w odniesieniu do liczby dni pracy pojazdu (rys. 7, rys. 8, rys. 9).



Rys. 7. Miesięczny przychód w odniesieniu do liczby dni pracy pojazdu



Rys. 8. Względny jednostkowy przychód w odniesieniu do liczby dni pracy pojazdu



Rys. 9. Względny zysk jednostkowy w odniesieniu do liczby dni pracy pojazdu

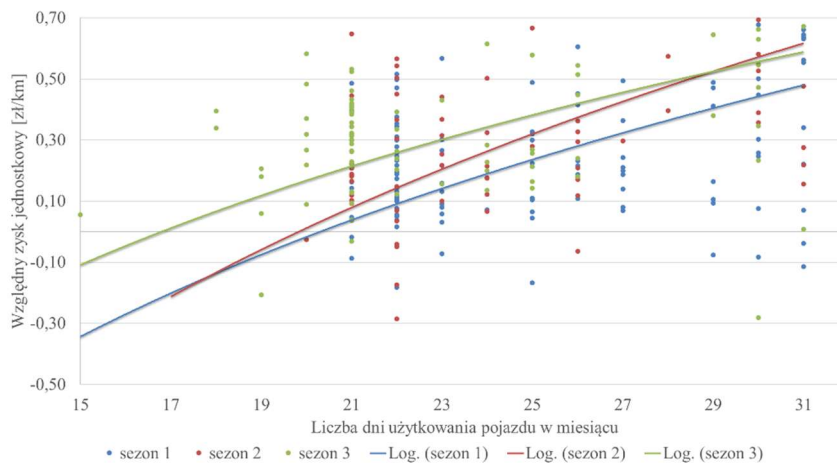
Z przeprowadzonej analizy również wynika, iż wybrana sieć prawidłowo odwzorowuje wybrane miary efektywności ekonomicznej.

W celu dokonania szczegółowej analizy wpływu tego czynnika na sygnał wyjściowy wyodrębniono wpływ pory roku na wartości miar efektywności w odniesieniu do liczby dni pracy pojazdu (rys. 10, rys. 11, rys. 12).


Na podstawie wywiadu z kierowcami pojazdów porę roku określono, jako ogólne warunki realizacji zleceń oraz komfort i bezpieczeństwo jazdy:

- sezon 1 przypisuje się miesiącom: maj, czerwiec, lipiec, sierpień,
- sezon 2: marzec, kwiecień, wrzesień, październik,
- sezon 3: styczeń, luty, listopad, grudzień.


Przeprowadzone badania wykazały, że najwyższe wartości miar efektywności osiąga się podczas eksploatacji samochodów dostawczych i realizacji zleceń w czasie sezonu 3, a najniższe w czasie sezonu 1. Potwierdzeniem tego jest fakt występowania sezonowości w obszarze świadczenia usług transportowych. Złe warunki atmosferyczne, określające sezon zimowy, to czas wzmożonego użytkowania pojazdów ze względu na rosnące zapotrzebowanie na usługi (sezon 3), przy zmniejszonej ich ofercie. Dobre warunki atmosferyczne obserwuje się w sezonie letnim, ale wówczas maleje zapotrzebowanie na usługi przewozowe (sezon 1). Podaż usług w analizowanym sektorze w tym okresie jest wyższa od popytu na usługi.



Rys. 10. Względny zysk jednostkowy w odniesieniu do liczby dni pracy pojazdu w odniesieniu do  $y^k$



Rys. 11. Względny jednostkowy przychód w odniesieniu do liczby dni pracy pojazdu w odniesieniu do  $y^k$



Rys. 12. Miesięczny jednostkowy przychód w odniesieniu do liczby dni pracy pojazdu w odniesieniu do  $y^k$

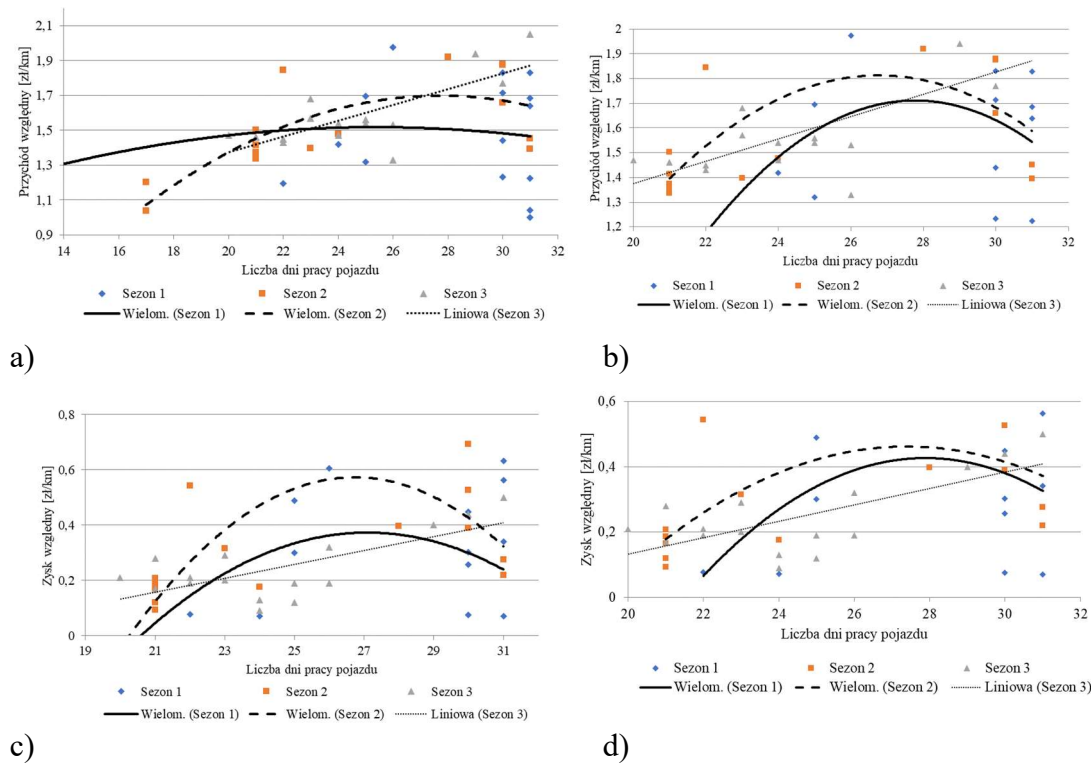
Weryfikację zaproponowanej metody przeprowadzono na podstawie wyników kolejnych obliczeń, dokonanych po wprowadzeniu do sieci neuronowej danych nie wykorzystanych w procesie uczenia. Przykładowe wyniki końcowe przedstawiono w tabeli 5.

Tabela 5. Przykładowe wyniki obliczeń przychodu, jednostkowego przychodu względnego i jednostkowego zysku względnego dla zbioru danych nie wykorzystanych w procesie uczenia

$P_Y^X$	$Y_D^U$	$Y_R^U$	$Y_I^U$	$Y_C^U$	$Y_P^U$	$Y_M^U$	$Y_E^U$	$Y_K^E$	$Y_W^K$	$Y_P^O$	$Y_K^O$	$Y_H^O$	$Y_M^E$	$Y_L^E$	$Y_W^E$
1	30	11360	425	480	15	1661	1,33	12873,13	sezon 2	tak	tak	tak	5976,87	1,66	0,53
2	31	13331	516	553	15	1771	1,61	15669,06	sezon 2	tak	tak	tak	2920,94	1,39	0,22
3	24	10127	422	454	15	1408	1,14	13172,67	sezon 2	tak	tak	tak	1787,33	1,48	0,18
4	30	13750	516	581	15	1887	1,45	16232,06	sezon 2	tak	tak	tak	9537,95	1,87	0,69
5	30	9470	350	427	15	1697	1,31	14113,56	sezon 2	tak	tak	tak	3686,44	1,88	0,39
6	28	10527	376	442	15	1556	1,64	16041,24	sezon 2	tak	tak	tak	4178,76	1,92	0,40
7	17	10700	684	784	15	1588	1,22	20263,87	sezon 2	tak	tak	tak	-7413,87	1,20	-0,69
8	31	16362	528	602	15	1765	1,36	19235,94	sezon 2	tak	tak	tak	4514,06	1,45	0,28
9	17	10700	684	784	15	1349	1,23	20120,94	sezon 2	tak	tak	tak	-9020,94	1,04	-0,84
10	21	7824	447	484	13	743	0,99	9727,43	sezon 2	tak	tak	tak	722,57	1,34	0,09
11	21	9632	459	491	14	1114	1,11	11636,10	sezon 2	tak	tak	tak	1593,90	1,37	0,17
12	23	10560	515	635	14	1190	1,04	11430,36	sezon 2	tak	tak	tak	3319,64	1,40	0,31
13	22	6990	350	430	14	1162	1,01	9105,71	sezon 2	tak	tak	tak	3794,29	1,85	0,54
14	21	8297	395	459	14	1263	1,05	10928,23	sezon 2	tak	tak	tak	1541,78	1,50	0,19
15	21	9090	433	497	14	1036	1,04	10968,52	sezon 2	tak	tak	tak	1881,48	1,41	0,21
16	21	8000	419	520	14	771	1,03	9847,90	sezon 2	tak	tak	tak	952,10	1,35	0,12
17	31	11760	380	445	15	1454	1,32	15814,58	sezon 1	tak	tak	tak	4005,42	1,69	0,34
18	26	8600	331	378	15	1561	1,25	11779,84	sezon 1	tak	tak	nie	5200,16	1,97	0,60
19	24	10570	441	538	15	1621	1,32	14242,71	sezon 1	tak	tak	tak	757,29	1,42	0,07
20	25	10980	440	503	15	1686	1,37	13236,73	sezon 1	tak	tak	nie	5363,27	1,69	0,49
21	31	13230	471	552	15	1802	1,39	15843,46	sezon 1	tak	tak	tak	8356,54	1,83	0,63
22	30	11520	384	472	15	1620	1,25	16784,69	sezon 1	tak	tak	tak	2965,31	1,71	0,26
23	31	14500	468	493	15	1642	1,26	16733,81	sezon 1	tak	tak	tak	1016,19	1,22	0,07
24	31	14400	465	502	15	1513	1,16	15500,69	sezon 1	tak	tak	tak	8099,31	1,64	0,56
25	22	11290	514	571	15	1563	1,20	12614,45	sezon 1	tak	tak	tak	865,55	1,19	0,08
26	30	14930	498	603	15	1645	1,73	16990,02	sezon 1	tak	tak	tak	4509,98	1,44	0,30
27	31	17810	575	613	15	1558	1,64	19222,32	sezon 1	tak	tak	tak	-672,32	1,04	-0,04
28	30	12860	429	530	15	1645	1,73	17773,67	sezon 1	tak	tak	tak	5766,33	1,83	0,45
29	30	17040	569	674	15	1807	1,39	19713,65	sezon 1	tak	tak	tak	1286,35	1,23	0,08
30	12	6850	571	663	15	1779	1,37	19805,28	sezon 1	tak	tak	tak	-11055,28	1,28	-1,61
31	31	17980	580	618	15	1584	1,22	20049,37	sezon 1	tak	tak	tak	-2049,37	1,00	-0,11
32	25	14400	576	680	15	1596	1,45	14674,60	sezon 1	tak	tak	tak	4325,40	1,32	0,30
33	31	10936	423	488	15	1597	1,42	15795,00	sezon 3	tak	tak	tak	5475,83	2,05	0,50
34	30	10304	405	466	15	1588	1,38	14079,57	sezon 3	tak	tak	tak	4563,86	1,77	0,44
35	29	8372	358	413	15	1679	1,41	12553,19	sezon 3	nie	nie	nie	3348,62	1,94	0,40
36	26	11752	503	598	15	1536	1,34	13012,55	sezon 3	tak	tak	tak	2188,21	1,33	0,19
37	26	10224	430	531	15	1430	1,30	13012,55	sezon 3	tak	tak	tak	3282,31	1,53	0,32
38	25	11422	472	548	15	1609	1,39	15104,38	sezon 3	tak	tak	tak	2220,28	1,56	0,19
39	25	8985	389	486	15	1473	1,34	12577,23	sezon 3	tak	tak	tak	1037,22	1,54	0,12
40	24	9015	391	488	15	1476	1,34	12564,77	sezon 3	nie	nie	nie	1176,01	1,54	0,13
41	23	10850	435	500	15	1614	1,39	14725,20	sezon 3	nie	nie	nie	3184,18	1,68	0,29
42	22	8902	441	524	14	1101	1,08	10680,49	sezon 3	nie	nie	nie	1885,16	1,45	0,21
43	21	8784	435	523	14	1112	1,09	10635,87	sezon 3	nie	nie	nie	2458,52	1,46	0,28
44	20	8761	434	523	14	1112	1,09	10628,81	sezon 3	nie	nie	nie	1839,10	1,47	0,21
45	23	11580	475	547	15	1646	1,40	15622,78	sezon 3	nie	nie	nie	2371,98	1,57	0,20
46	21	9126	434	518	14	1158	1,15	11411,48	sezon 3	nie	nie	nie	1562,54	1,46	0,17
47	22	8903	437	530	14	1066	1,10	10670,73	sezon 3	nie	nie	nie	1702,55	1,43	0,19
48	24	9126	409	502	15	1461	1,24	12763,30	sezon 3	tak	tak	tak	801,64	1,47	0,09

Na podstawie globalnej analizy wrażliwości i otrzymanych wyników (tabela 5) można stwierdzić, iż przychód wzrasta wraz ze wzrostem liczby dni pracy pojazdu. Przychód względny i zysk względny został poniżej obliczony na dwa sposoby: uwzględniając wszystkie

warianty zleceń wraz z tymi, które generują stratę oraz uwzględniając tylko warianty przynoszące zysk z realizacji zlecenia.



Rys. 13. Wyniki obliczeń przychodu i zysku względnego w funkcji liczby dni pracy pojazdu

Badania wykazały też, że istotnym czynnikiem wpływającym na przebieg zależności pomiędzy liczbą dni pracy, a przychodem lub zyskiem jest również pora roku. Sezon determinuje tempo wzrostu przychodu względnego i zysku względnego. Tempo to jest wysokie w przedziale 10-22 dni pracy pojazdów i staje się umiarkowane w przedziale 23-25 dni pracy w miesiącu. Natomiast zwiększanie liczby dni pracy powyżej 26-27 nie daje już przyrostu korzyści. Wyniki przedstawione na rys. 13c) potwierdzają, że w celu osiągnięcia zysku względnego pojazdy powinny być użytkowane nie mniej niż 20 dni w miesiącu, natomiast analiza przewidywań bez uwzględniania zleceń powodujących straty (rys. 13d) potwierdza, że jest to powyżej 21 dni pracy dla sezonu 2 oraz 22 dni dla sezonu 1.

## 6. Podsumowanie

Otrzymane i przedstawione w artykule wyniki pozwoliły na następujące stwierdzenia, iż przyjęte miary efektywności ekonomicznej pokazały wpływ liczby dni pracy pojazdów na przychód i zysk z usług transportowych oraz że opracowany model jest przydatny do predykcji miesięcznego przychodu z usług przewozowych.

Wyniki obliczeń dają podstawę do stwierdzenia, że zwiększanie liczby dni pracy pojazdu ma ograniczony wpływ na proces narastania przychodu w firmie. Obserwuje się, że dodatnie wartości przychodu są osiągnięte przy liczbie dni pracy powyżej 19-20.

Zarówno liczba, jak i rodzaj danych, wykorzystanych w sieci neuronowej pozwoliły na osiągnięcie wysokich wyników analiz, na poziomie 80-90% skuteczności.

Uzyskane wyniki obliczeń pokazały specyficzne cechy wpływu liczby dni pracy na przychód w firmie transportowej. Wzrost liczby dni pracy sprzyja wzrostowi przychodu w sposób ograniczony, a to ograniczenie zależy od pory roku.

Opracowany model sieci neuronowej umożliwił wspomaganie podejmowania decyzji w realizacji procesów transportowych, uwzględniających efektywność ekonomiczną procesu eksploatacji pojazdów samochodowych. Tym samym uzyskane rezultaty pokazały przydatność przyjętych miar efektywności ekonomicznej oraz zbudowanego modelu do predykcji (przewidywania) rezultatów ekonomicznych działalności transportowej firmy.

## Literatura

- [1] Aleksandrowicz P, Żółtowski B. Vehicle repair costs calculation systems. Polish Association for Knowledge Management. Warszawa: BEL Studio sp. z o.o., 2010.
- [2] Andrzejczak K, Młyńczak M, Selech J. Poisson-distributed failures in the predicting of the cost of corrective maintenance. *Eksplatacja i Niezawodność - Maintenance and Reliability* 2018; 20 (4): 602-609, <https://doi.org/10.17531/ein.2018.4.11>.
- [3] Biesok G. *Logistyka Usług*. Warszawa: CeDeWu, 2013.
- [4] Bronk H. Cechy i układ kosztów w transporcie umożliwiające podejmowanie decyzji. *Koszty i ceny w transporcie. Pomiar i analiza*. Szczecin: Zeszyty naukowe 813, 2014; 21 – 38.
- [5] Chen X, Xiao L, Zhang X, Xiao W, Li J. An integrated model of production scheduling and maintenance planning under imperfect preventive maintenance. *Eksplatacja i Niezawodność – Maintenance and Reliability* 2015; 17 (1): 70–79.
- [6] Chłopek Z, Bebkiewicz K. Model of the structure of motor vehicles for the criterion of the technical level on account of pollutant emission. *Eksplatacja i Niezawodność – Maintenance and Reliability* 2017; 19 (4): 501-507, <http://dx.doi.org/10.17531/ein.2017.4.2>.
- [7] Coupek D, Gulec A, Lechler A, Verl A. Selective rotor assembly using fuzzy logic in the production of electric drives. *Conference on Intelligent Computation in Manufacturing Engineering*, 2014.
- [8] Gohari A, Matori N A, Yusof K W, Toloue I, Sholagberu A T. The effect of fuel price increase on transport cost of container transport vehicles. *International Journal of GEOMATE* 2018; 15: 174-181.
- [9] Himanen V, Nijkamp P, Reggiani A. *Neural networks in transport applications*. Ashgate 1998. Reissued 2018 by Routledge.
- [10] Józwiak A. Application of Kohonen's Network in Logistics. *Gospodarka Materialowa i Logistyka* 2017; 5: 258-271.
- [11] Kijek M, Brzeziński M, Gontarczyk M, Rykała Ł, Zelkowski J. Fuzzy Modeling of Evaluation Logistic Systems. *Transport Means* 2017; 2: 377-382.
- [12] Kleiner F, Friedrich H E. Development of a Transport Application based Cost Model for the assessment of future commercial vehicle concepts. Geneva: European Battery, Hybrid and Fuel Cell Electric Vehicle Congress, 2017.
- [13] Kowalski M, Magott J, Nowakowski T, Werbińska-Wojciechowska T. Analysis of transportation system with the use of Petri nets *Eksplatacja i Niezawodność – Maintenance and Reliability* 2011; 1 (49): 48–62.
- [14] Koźlak A. *Ekonomika transportu. Teoria i praktyka*. Gdańsk: Wydawnictwo Uniwersytetu Gdańskiego, 2010.
- [15] Mendyk E. *Ekonomika transportu*. Poznań: Wyższa Szkoła Logistyki, 2009.
- [16] Niewczas A, Rymarz J, Debicka E. Stages of operating vehicles with respect to operational efficiency using city buses as an example. *Eksplatacja i Niezawodność – Maintenance and Reliability* 2019; 21 (1): 21–27, <http://dx.doi.org/10.17531/ein.2019.1.3>.



- [17] Oziemski S. Efektywność eksploatacji maszyn. Podstawy techniczno – ekonomiczne. Radom: Biblioteka problemów eksploatacji, 1999.
- [18] Prochowski L. Evaluation of the process of mileage growth during the operation of motor trucks, in several categories of engine cubic capacity. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2018; 20 (3): 359–370, <http://dx.doi.org/10.17531/ein.2018.3.3>.
- [19] Raporty z Internetu Głównego Inspektoratu Transportu Drogowego.
- [20] Rudyk T, Szczepański E, Jacyna M. Safety factor in the sustainable fleet management model. *Archives of Transport* 2019; 49: 103-114.
- [21] Świdorski A, Borucka A, Jacyna-Gołda I, Szczepański E. Wear of brake system components in various operating conditions of vehicle in the transport company. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2019; 21 (1): 1–9, <http://dx.doi.org/10.17531/ein.2019.1.1>.
- [22] Świdorski A, Józwiak A, Jachimowski R. Operational quality measures of vehicles applied for the transport services evaluation using artificial neural networks. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2018; 20 (2): 292–299, <http://dx.doi.org/10.17531/ein.2018.2.16>.
- [23] Świdorski A. Studies and quality assurance neural modelling of the technical transport means. *Archive of Transport. Polish Academy of Sciences Committee of Transport* 2009; 21 (3-4).
- [24] Teodorovic D, Vukadinovic K. *Traffic Control and Transport Planning:: A Fuzzy Sets and Neural Networks Approach*. Springer Science+Business Media 2012.
- [25] Urbanyi-Popiołek I. *Ekonomiczne i organizacyjne aspekty transportu*. Bydgoszcz: Wyższa Szkoła Gospodarki, 2013.
- [26] Witkowski K, Tanona K. Analiza kosztów transportu drogowego. *Logistyka* 2013; 5: 411 – 416.
- [27] Zał. nr 2. do U. z dnia 20 czerwca 1997 r. Prawo o ruchu drogowym.

### **Analysis of the impact of the use time of N1 motor vehicles on the economic efficiency of their maintenance**

**Keywords:** *operation of vehicles, motor vehicles of category N1, economic efficiency, neural networks*

**Abstract:** The efficiency of operation of motor vehicles with a DMC (Permissible Laden Mass) <3.5 tonnes is considered. These are vehicles belonging motor vehicles of category N1, usually referred to as delivery vehicles. The results of observations on the implementation of transport orders in 7 transport companies from the MŚP (Small and Middle-size Companies) sector were used to conduct the effectiveness analysis. The research group covered 24 vehicles that implementation transport orders in the urban zone and in the immediate vicinity of the city. Information was collected on a monthly basis.

During the analysis of economic efficiency the income measures (absolute and relative) were used. The calculations were carried out using the model of the vehicle operation process in the form of a neural network, in which a set of 12 input variables and 3 output variables were taken into account. Using the Statistica 13.3 computer program and defining the group and factors describing the process of implementation of individual transport tasks, the developed neural network model enabled searching for the impact of selected operational factors on the economic efficiency of N1 category cars.

The calculations showed a significant impact of the number of vehicle days in a month, the weight of the load, as well as the time of year. The obtained calculation results showed the specific features of the impact of the number of working days on revenue in a transport company. The increase in the number of working days favors the increase in income in a limited way, and this restriction depends, among others since the time of year.