

ISBN 978-83-959742-1-2

# Conference proceedings Transport Problems 2021

XIII INTERNATIONAL  
SCIENTIFIC  
CONFERENCE

X INTERNATIONAL  
SYMPOSIUM OF YOUNG  
RESEARCHERS

28.06-30.06 2021  
Katowice - Silesia  
(online)



Silesian  
University  
of Technology



Ministry of Economic Development,  
Labour and Technology

Krajowa  
Reprezentacja  
Doktorantów

**KRD**



UNDER THE HONORARY PATRONAGE OF



Silesian University of Technology  
Faculty of Transport and Aviation Engineering

# Transport Problems 2021

## Proceedings

XIII International Scientific Conference

X International Symposium of Young Researchers

UNDER THE HONORARY PATRONAGE OF



Ministry of Economic Development,  
Labour and Technology



Silesian University  
of Technology

Krajowa  
Reprezentacja  
Doktorantów

**KRD**

ISBN 978-83-959742-1-2

Transport Problems  
*International Scientific Journal*

*editor-in-chief*  
**A. Sładkowski**  
*editorial board*

*P. Czech, M. Cieśla, T. Haniszewski,  
M. Juzek, W. Kamiński, P. Marzec, G. Wojnar*

*CONFERENCE -  
TABLE OF  
CONTENTS*

*SYMPOSIUM -  
AUTHORS LIST*

*CONFERENCE &  
SYMPOSIUM  
PROGRAM*

*CONFERENCE -  
TABLE OF  
PRESENTATIONS*

*CONFERENCE &  
SYMPOSIUM  
PROCEEDINGS*

*CONFERENCE &  
SYMPOSIUM  
PARTICIPANTS*

No.	Author, title	Pages	
		Begin	End
10	Ladislav BARTUSKA, Ondrej STOPKA, Jiri HANZL, Josef SEDIVY, Iwona RYBICKA <i>Changes in transport behaviour of Czech population caused by state of emergency</i>	<a href="#">101</a>	112
11	Dinara BASHIROVA <i>Building a local model of a quasigeoid for the construction and reconstruction of highways</i>	<a href="#">113</a>	124
12	Anna BORUCKA, Patrycja GUZANEK <i>Analysis of the seasonality of passenger railway transport in the aspect of their development</i>	<a href="#">125</a>	136
13	Artur BUDZYŃSKI, Aleksander ŚLADKOWSKI <i>Predicting freight price in road transport with using artificial neural networks</i>	<a href="#">137</a>	151
14	Wioletta CEBULSKA, Damian HADRYŚ, Marek JASIOK <i>Contaminations of the diesel fuel as the cause of wear of the injection system components</i>	<a href="#">152</a>	160
15	Merab CHELIDZE, Victor ZVIADAURI <i>Some problems arising in the mathematical modeling of electromagnetic vibrators used for the transporting of bulk materials</i>	<a href="#">161</a>	172
16	Oleg CHISLOV, Viktor BOGACHEV, Vyacheslav ZADOROZHNIY, Alexandra KRAVETS, Maksim BAKALOV <i>Development of methods for mathematical modeling transport processes management in port transport systems</i>	<a href="#">173</a>	178
17	Janusz ĆWIEK <i>Heat treatment of railway wheels</i>	<a href="#">179</a>	185
18	Jan FILIPCZYK <i>Human factor in cyclists safety – results of survey</i>	<a href="#">186</a>	195
19	Andrea GALIERIKOVÁ, Matúš MATERNA <i>Regression analysis of safety and efficiency of water transport</i>	<a href="#">196</a>	207
20	Damian GAŚKA, Jerzy MARGIELEWICZ, Tomasz HANISZEWSKI, Tadeusz OPASIAK <i>Trajectory of crane hoist load movement for periodic and chaotic solutions</i>	<a href="#">208</a>	213
21	Pavels GAVRILOVS, Janis EIDUKS, Dmitrijs GORBACOVS <i>Determination of the metal structure, analysis of the chemical composition, testing of hardness and determination off static breaking stresses of the fastening bolts of the rubber-cord coupling for traction gear of electric trains of the ER2T series</i>	<a href="#">214</a>	226

**Key words:** road transport, artificial neural networks, predicting price

**Artur BUDZYŃSKI\***, Aleksander SŁADKOWSKI

Silesian University of Technology, Faculty of Transport and Aviation Engineering

Krasińskiego 8, 40-019 Katowice, Poland

\*Corresponding author. Email: [artur.budzynski@polsl.pl](mailto:artur.budzynski@polsl.pl)

## PREDICTING FREIGHT PRICE IN ROAD TRANSPORT WITH USING ARTIFICIAL NEURAL NETWORKS

**Summary.** The main goal of this article is to present the possibilities of using artificial neural networks for predict freight price. The problem of calculating the price for the road transport service is presented. A proposal for a ready-made and working tool based on neural networks is presented. It shows what the model for prediction consists of. Different networks are compared how they cope with prediction. The problems that arose while cleaning and preparing the data for analysis are presented, and how they deal with it. A detailed analysis of the best quality network shows the number of hidden layers in the network and what input and output functions are used.

## PREDYKCJA CEN W TRANSPORCIE DROGOWYM Z WYKORZYSTANIEM SZTUCZNYCH SIECI NEURONOWYCH

**Streszczenie.** Głównym celem artykułu jest przedstawienie możliwości wykorzystania sztucznych sieci neuronowych do predykcji ceny za transport. Przedstawiono problematykę kalkulacji ceny za usługę transportu drogowego. Zaproponowano zastosowanie narzędzia opartego na sztucznych sieciach neuronowych. Przetawiono krok po kroku jak zbudować model do predykcji cen. Omówiono problem konwersji zebranych danych na użyteczne w modelu. Opisano z czego składają się poszczególne sieci neuronowe i czym się różnią między sobą. Przeprowadzono eksperyment sprawdzający użyteczność modelu w codziennej pracy.

### 1. WSTĘP

Przygotowanie wyceny usługi transportowej to złożony proces. Na ostateczny koszt składa się wiele czynników. Jednym z głównych kosztów jest paliwo. Istnieje oczywista korelacja między masą towaru a ilością zużytego paliwa. Transport cięższych ładunków powoduje większe spalanie paliwa. Równie oczywista jest zależność ilości spalanego paliwa od odległości między miejscem załadunku, a rozładunkiem. Im dłuższa trasa, tym więcej paliwa jest spalane. Pozwala to na zaklasyfikowanie paliwa jako kosztu zależnego od odległości. Ceny paliw w poszczególnych krajach różnią się z wielu powodów.

Opłaty drogowe są zasadniczo podzielone na dwie grupy. Pierwszy to system opłat oparty zależny od długości pokonanego dystansu. W przypadku opłat drogowych istnieją automatyczne systemy poboru opłat i opłaty na bramkach autostrad. Drugi to opłata zależna od czasu w formie winiety. Opłaty drogowe obowiązują w: Polsce, Niemczech, Belgii, Francji, Włoszech, Irlandii, Grecji, Portugalii,

Austrii, Bułgarii, Chorwacji. Winiety obowiązują w: Holandii, Luksemburgu, Danii, Szwecji, Czechach, Litwie, Łotwie, Estonii, Słowenii, Węgrzech i Rumunii. Drogi w Finlandii, na Malcie i Cyprze są bezpłatne. Powyższy podział odnosi się do pojazdów ciężarowych o masie całkowitej powyżej 3,5 tony. Opłaty drogowe często zależą od klasy emisji i kategorii pojazdu [1].

Koszty kierowców i osób wspierających kierowcę w pracy zależą od czasu. Kierowcy często otrzymują wynagrodzenie w zależności od tego, ile dni spędzają w pracy i w jakich krajach. Kierowcy pracujący za granicą muszą otrzymywać wynagrodzenie zgodnie z lokalnymi przepisami. Firma świadcząca usługi w Niemczech musi płacić pracownikowi zgodnie z ustawą regulującą ogólne wynagrodzenie minimalne (ustawa o minimalnym wynagrodzeniu - MiLoG)[2]. Serwis zestawu jest kosztem zależnym zarówno od czasu, jak i przebiegu. Niektóre elementy pojazdu wymagają serwisu w określonej jednostce czasu. Inne elementy wymagają serwisu po przejechaniu określonego przebiegu. W przypadku świadczenia usług transportowych wymagane i zalecane są ubezpieczenia. Wszystkie są zawierane na określony czas. Główne koszty zależne od odległości: paliwo, opłaty drogowe, serwis. Główne koszty zależne od czasu: winiety, koszty pracownicze, amortyzacja, leasing, serwis i ubezpieczenie.

Załadunek i rozładunek pojazdu zajmują czas. Czas pracy i jazdy kierowcy jest ograniczony. Biorąc to pod uwagę można stwierdzić, że dłuższe transporty powinny być tańsze w przeliczeniu na tonokilometr niż krótsze trasy. W transporcie drogowym występuje zróżnicowanie podaży i popytu między różnymi regionami i krajami. Zależności od podaży i popytu wpływają na ceny transportu.

Sztuczne sieci neuronowe to model składający się z połączonych ze sobą neuronów. Połączenia między neuronami mają określone wagi. Proces uczenia się sieci neuronowej modyfikuje wagi. Na początku sieć neuronowa otrzymuje sygnały wejściowe. Na końcu daje sygnały wyjściowe [3].

Do przewidywania zużycia paliwa na statkach wykorzystano sieci neuronowe. Danymi wejściowymi do sieci były: stan morza i wiatru, ilość ładunku, prędkość, przegłębienie, zanurzenie, obroty na minutę. Na wyjściu było zużycie paliwa. Naukowcy wykorzystali oprogramowanie MATLAB. Jako walidację zastosowano analizę regresji wielokrotnej. Badanie potwierdziło, że zużycie paliwa można przewidzieć za pomocą sieci neuronowej [4].

Prognozę ceny ropy wykonano z wykorzystaniem sieci neuronowej. Zastosowano model GEP. Zastosowano algorytm wstecznej propagacji błędów. Badania potwierdziły, że model GEP przewyższa inne w prognozowaniu ceny ropy. Autorzy argumentują, że takie badanie można wykorzystać do przewidywania innych surowców, jak złoto i metale szlachetne [5].

Rozwój sztucznej inteligencji jest wspierany przez polski rząd. Opublikowano uchwałę 196 Rady Ministrów z dnia 28 grudnia 2020 r. W sprawie ustalenia „Polityki rozwoju sztucznej inteligencji w Polsce od 2020 r.”. Proces cyfrowej transformacji społeczeństwa i gospodarki z wykorzystaniem algorytmów to wielkie wyzwanie rozwojowe XXI wieku. Usługi publiczne i komercyjne oraz przemysł muszą zostać głęboko nasycone danymi, aby wejść w erę sztucznej inteligencji. W ostatnich latach dane stały się jednym z najważniejszych czynników produkcji. Pozyskiwanie, gromadzenie, analiza, przetwarzanie i świadome wykorzystywanie danych oraz ciągły rozwój algorytmów AI stają się podstawową kompetencją gospodarek i państw. Kompetencja ta determinuje ich miejsce w globalnym łańcuchu dostaw oraz wartość dodaną przetwarzania danych w dziedzinie sztucznej inteligencji aplikacji [6].

Giełda transportowa to miejsce, które łączy podmioty posiadające towary do przewiezienia z podmiotami posiadającymi wolną przestrzeń ładunkową. Dane z ogłoszeń mogą być z powodzeniem wykorzystane do badań i analiz.

## 2. PRZYGOTOWANIE DANYCH I TWORZENIE NOWYCH CECH

Dane do badania pochodzą z jednej z najważniejszych giełd transportowych oraz ze zleceń realizowanych przez małe firmy transportowe z województwa śląskiego. Przewozy skupiają się na przewozach realizowanych pomiędzy Polską i sąsiednimi krajami: Słowacją, Czechami, Niemcami i Szwecją. Firmy skupiają swoją działalność w tych krajach. Dane o zleceniach transportowych pochodzą

z transportów oferowanych w przeszłości. Tabela 1 przedstawia wszystkie cechy dotyczące transportów wraz z przykładem podanym, aby dobrze zrozumieć każdą cechę.

Tab. 1

Lista cech analizowanych danych wraz z przykładem

Cecha	Przykład
Miejsce załadunku	PL43150
Miejsce rozładunku	DE97177
Data początku załadunku	2020-11-02
Czas początku załadunku	12:30
Data końca załadunku	2020-11-02
Godzina końca załadunku	12:30
Data początku rozładunku	2020-11-03
Czas początku załadunku	09:00
Data końca rozładunku	2020-11-03
Czas końca rozładunku	09:00
Typ pojazdu	Pojazd z przyczepą, Ciągnik z naczepą
Typ nadwozia	Chłodnia
Ilość Euro palet na wymianę	0
Temperatura Minimalna	1
Temperatura Maksymalna	5
Typ towaru	Jogurt
Metoda załadunku/rozładunku	Tył
Odległość w Czechach [km]	0
Odległość w Niemczech [km]	469.4
Odległość w Polsce [km]	364.1
Odległość w Szwecji [km]	0
Odległość w Słowacji [km]	0
Metry ładunkowe	13.6
Waga [t]	22.5
Cena [€]	950

Model oczekuje wartości liczbowych. Należy znaleźć sposób na to jak zapisać powyższe cechy za pomocą liczb, tak aby dały jak najlepszy efekt. Proces tworzenia nowych cech nazywa się z języka angielskiego: "feature engineering".

### 2.1. Miejsce załadunku

Miejsce załadunku składa się z 2 liter przedstawiających kod danego kraju i 5 cyframi stanowiącymi kod pocztowy. Przygotowując dane do modelu zdecydowano się na system przypisujący do cechy wartość 0 lub 1, z podziałem na wszystkie kraje. Cena różni się w zależności od kraju załadunku. LP w nazwie funkcji oznacza miejsce załadunku z angielskiego "Load Place". Proces konwersji cechy przedstawiono w tabeli 2.

## 2.2. Miejsce rozładunku

Miejsce rozładunku składa się z 2 liter przedstawiających kod danego kraju i 5 cyframi stanowiącymi kod pocztowy. Przygotowując dane do modelu zdecydowano się na system przypisujący do cechy wartość 0 lub 1, z podziałem na wszystkie kraje. Cena różni się w zależności od kraju rozładunku. DP w nazwie funkcji oznacza miejsce rozładunku z angielskiego "Delivery Place". Proces konwersji cechy przedstawiono w tabeli 3.

Tab. 2

Proces konwersji cechy „Miejsce załadunku”

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Miejsce załadunku	PL43150	CZ_LP	0
		DE_LP	0
		PL_LP	1
		SE_LP	0
		SK_LP	0

Tab. 3

Proces konwersji cechy „Miejsce rozładunku”

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Miejsce rozładunku	DE97177	CZ_DP	0
		DE_DP	1
		PL_DP	0
		SE_DP	0
		SK_DP	0

## 2.3. Data

Data jest ważną cechą ze względu na występującą w transporcie drogowym sezonowość. Dzień tygodnia może również wpływać na cenę w różnych relacjach. Na podstawie tych danych można stwierdzić, czy załadunek był wymagany w określonym dniu, czy też był on elastyczny. Ładunki z elastycznym terminem załadunku i rozładunku dają więcej możliwości, co może przełożyć się na niższą cenę. Daje to możliwość doboru środka transportu będącego bliżej, zmniejszając puste przebiegi. Dzień tygodnia jest reprezentowany przez liczbę, gdzie poniedziałek = 1, wtorek = 2, środa = 3, czwartek = 4, piątek = 5, sobota = 6, niedziela = 7. Cecha data początku załadunku określa, w którym dniu można rozpocząć ładowanie najwcześniej. Z każdej z tych cech utworzono 4 nowe, są to: dzień miesiąca, dzień tygodnia, miesiąc i rok. „SL” w nazwie funkcji oznacza z angielskiego „Start Load”. Cecha data końca załadunku określa, w którym dniu trzeba najpóźniej załadować towar. „EL” w nazwie funkcji oznacza z angielskiego „End Load”. Cecha data końca załadunku określa, w którym dniu można najwcześniej rozładować towar. „SD” w nazwie funkcji oznacza z angielskiego „Start Delivery”. Cecha data końca załadunku określa, w którym dniu trzeba najpóźniej rozładować towar. „ED” w nazwie funkcji oznacza z angielskiego „End Delivery”.

## 2.4. Czas

Czas ładowania ma wpływ na cenę. Transport towaru, który można ładować przez cały dzień, będzie tańszy niż ten z załadunkiem awizowanym. Jest to związane z optymalnym wykorzystaniem czasu pracy i jazdy. Załadunki wymagające pracy w porze nocnej ograniczają czas pracy w danej dobie zgodnie z przepisami. Cecha czas początku załadunku określa najwcześniejszy czas rozpoczęcia ładowania. SL w



nazwie funkcji oznacza z angielskiego „Start Load”. Cecha czas końca załadunku określa najpóźniejszy czas rozpoczęcia ładowania. EL w nazwie funkcji oznacza z angielskiego „End Load”. Cecha czas początku rozładunku określa najwcześniejszy czas rozpoczęcia rozładunku. SD w nazwie funkcji oznacza z angielskiego „Start Delivery”. Cecha czas końca rozładunku określa ostateczny czas rozładunku. EL w nazwie funkcji oznacza z angielskiego „End Delivery”. Z każdej cechy dotyczącej czasu wyciągnięto 2 nowe, jest to godzina i minuta. Proces konwersji cechy przedstawiono w tabeli 5.

Tab. 4

Proces konwersji cech dotyczących daty

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Data początku załadunku	2020-11-02	D_SL	2
		WD_SL	1
		MO_SL	11
		Y_SL	2020
Data końca załadunku	2020-11-02	D_EL	2
		WK_EL	1
		MO_EL	11
		Y_EL	2020
Data początku rozładunku	2020-11-03	D_SD	3
		WK_SD	2
		MO_SD	11
		Y_SD	2020
Data końca rozładunku	2020-11-03	D_ED	3
		WK_ED	2
		MO_ED	11
		Y_ED	2020

Tab. 5

Proces konwersji cech dotyczących godziny

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Czas początku załadunku	12:30	H_SL	12
		MI_SL	30
Czas końca załadunku	12:30	H_EL	12
		MI_EL	30
Czas początku rozładunku	9:00	H_SD	9
		MI_SD	0
Czas końca rozładunku	9:00	H_ED	9
		MI_ED	0

## 2.5. Typ pojazdu

Możliwość transportu różnymi typami pojazdów może obniżyć koszty ze względu na większe prawdopodobieństwo znalezienia pojazdu bliżej. Analizowane zamówienia miały 2 wartości w wymaganym typie pojazdu: „Pojazd z przyczepą”, „Ciągnik z naczepą”. Wszystkie zamówienia miały cechę „Ciągnik z naczepą”, więc nie jest to zmienna. Zdecydowano się przypisać 0 lub 1 do „Pojazd z przyczepą”. Konwersję cech przedstawiono w tabeli 6.

Tab. 6

Proces konwersji cechy „Typ pojazdu”

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Typ pojazdu	Pojazd z przyczepą, Ciągnik z naczepą	Pojazd z przyczepą	1

## 2.6. Typ zabudowy

Możliwość załadunku towarów na różne typy przyczep pozwala obniżyć koszty transportu. Ładunki neutralne ładowane od tyłu będą mogły być ładowane na wiele typów naczep. Zwiększa to szansę na znalezienie pojazdu bliżej, co może obniżyć koszty transportu poprzez zmniejszenie pustych przebiegów. Na podstawie tej jednej cechy określono 6 na podstawie różnych typów przyczep w danych. Są to: Firanka, Termo, Chłodnia, Plandeka, Mega, Sztynna zabudowa. Konwersję cech przedstawiono w tabeli 7.

Tab. 7

Proces konwersji cechy „Typ zabudowy”

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Typ zabudowy	Chłodnia	Firanka	0
		Termo	0
		Chłodnia	1
		Plandeka	0
		Mega	0
		Sztynna zabudowa	0

## 2.7. Ilość E-Palet do wymiany

Koszt transportu może się zwiększyć w związku z koniecznością wymiany palet. Nie wszystkie pojazdy mają na stanie palety. Często występują problemy z wymianą palet. Na miejscu załadunku może się okazać, że palety są złej jakości i ich nie przyjmą - wtedy przewoźnik dostaje obciążenie. Rozładunek może zwrócić stare i uszkodzone palety. Ze względu na dużą konkurencję na rynku przewozów drogowych problemem jest słaba pozycja negocjacyjna przewoźnika w takiej sytuacji. Spory w takiej sytuacji mogą się okazać stratą klienta. W tym przypadku nie ma wiele do konwersji. W modelu liczba to po prostu liczba palet do wymiany. Brak wymiany oznacza 0. „EPALE” oznacza „EPAL Exchange”. Konwersję cech przedstawiono w tabeli 8.

Tab. 8

Proces konwersji cechy „EPAL Exchange”

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Wymiana EPalet	0	EPALE	0

**2.8. Temperatura**

Samo wymaganie kontrolowanej temperatury podnosi koszt transportu ze względu na konieczność przetransportowania go specjalną przyczepą chłodniczą. Agregat do chłodzenia lub ogrzewania towarów zużywa paliwo. W oparciu o minimalną i maksymalną temperaturę stworzono nową funkcję zakresu temperatur. Agregat chłodniczy można ustawić na stałą temperaturę w trybie ciągłym lub w trybie automatycznym z określonym zakresem temperatur. Zużycie paliwa w trybie automatycznym będzie niższe, co pozwoli nam uwzględnić cechę Temp\_zakres będąca po prostu różnicą między temperaturą maksymalną a minimalną. Konwersję cech przedstawiono w tabeli 9.

Tab. 9

Proces konwersji danych o temperaturze

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Temperatura Min.	1	Temp_min	1
		Temp_zakres	4
Temperatura Max.	5	Temp_max	5

**2.9. Typ towaru**

Cena za transport może się różnić w zależności od rodzaju przewożonego towaru. Wartość towaru różni się w zależności od rodzaju. Drogie towary wymagają specjalnego ubezpieczenia. Typy towarów różni czas ich załadunku. Do niezdefiniowanego rodzaju towaru, który jest powszechny w przypadku ofert giełdowych, przypisano właściwość „Różne”. Konwersję cech przedstawiono w tabeli 10.

Tab. 10

Proces konwersji cechy „Typ towaru”

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Typ towaru	Jogurt	Różne	0
		Inne	0
		Mrożone	0
		Jogurt	1
		Stal	0

**2.10. Metoda załadunku/rozładunku**

Cena transportu uzależniona jest od sposobu załadunku i rozładunku. Argumentem jest to, że załadunek tylny jest najpowszechniejszy w przypadku typów naczep, podczas gdy załadunek od góry jest najrzadszy. Konwersję cech przedstawiono w tabeli 11.

Tab. 11

## Proces konwersji cechy „Metoda załadunku/rozładunku”

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Metoda załadunku/rozładunku	Tył	Tył	1
		Góra	0
		Bok	0

**2.11. Dystans**

Oczywiste jest, że cena transportu zależy od przebytej odległości. Model uwzględnia zróżnicowanie liczby kilometrów w poszczególnych krajach. Jest to ważne ze względu na zróżnicowanie opłat drogowych. Odzwierciedla zebrane dane i dodatkowo podsumowuje liczbę kilometrów. Konwersję cech przedstawiono w tabeli 12.

**2.12. Metry ładunkowe, waga i cena**

W tej części przedstawiono jedne z najważniejszych danych. Wszystkie transporty są ładunkami cało pojazdowymi, więc metry ładunkowe nie są zmienną i zostały pominięte w modelu. Dla ceny transportu kluczowe znaczenie ma, ile przestrzeni ładunkowej zajmuje towar. Metr ładunkowy na naczepie ma szerokości 2,4 metra. Ilość metrów ładunkowych jest zawsze podawaną jednostką w ofertach. Jej umieszczenie jest warunkiem koniecznym do dodania oferty na giełdzie transportowej. Wysokość towaru nie jest zawsze podawana w zleceniach i ofertach. Standardowe naczepy mają wysokość 2,6 metra, więc przyjmuje się że towar ma nie więcej niż ta wysokość. Jeżeli towar jest wyższy wymagana jest naczepa typu „Mega” mającą wysokość przestrzeni ładunkowej 3 metry. Waga i cena odzwierciedlają dokładnie zebrane dane. Cena jest zmienną wyjściową, którą sieć neuronowa ma nauczyć się przewidywać. Konwersję cech przedstawiono w tabeli 13.

Tab. 12

## Proces konwersji danych dotyczących dystansu

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Dystans in CZ [km]	0	CZ_KM	0
Dystans in DE [km]	469.4	DE_KM	469.4
Dystans in PL [km]	364.1	PL_KM	364.1
Dystans in SE [km]	0	SE_KM	0
Dystans in SK [km]	0	SK_KM	0
Suma dystansu [km]		KM	833.5

Tab. 13


## Proces konwersji danych długości, wagi i ceny

Cecha	Przykładowa wartość cechy	Skonwertowane cechy	Skonwertowany przykład
Metry ładunkowe [ldm]	13.6		
Waga [t]	22.5	Tony	22.5
Cena [€]	950	Euro	950

### 3. BUDOWA MODELU

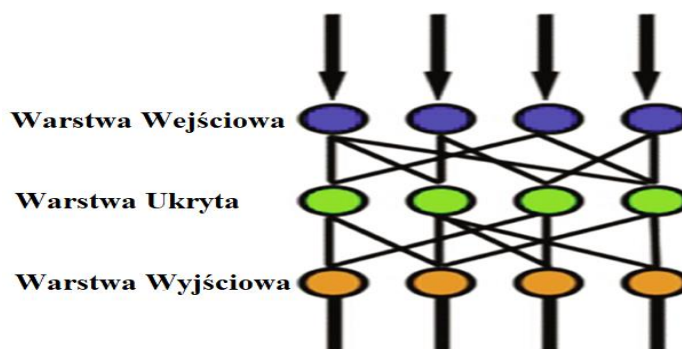
Bardzo dobrym sposobem na lepsze zrozumienie danych i generowanie nowych pomysłów w przyszłych projektach jest tworzenie różnych wykresów i szukanie w nich relacji. Modelowanie w sieciach neuronowych często rozpoczyna się od bardzo prostych modeli. Na podstawie tak prostych rozważań można stwierdzić, czy sformułowane hipotezy mają sens. Model z bardzo małą liczbą zmiennych nazywany jest modelem podstawowym. W trakcie tego badania też zaczęto od takich fundamentów. Oczywiście jest, że im dalej trzeba przetransportować towar i im coś jest cięższe, tym jest droższe. Przedstawiono to na Rys. 1. Potwierdza to znaczenie kluczowych założeń.

Do uczenia sieci neuronowych wykorzystano SANN Statistica firmy TIBCO. Można wybrać między innymi rodzaj sieci neuronowej, aktywację, neurony wyjściowe, liczbę sieci ukrytych [7]. Perceptron wielowarstwowy składa się z trzech rodzajów warstw: warstwy wejściowej, warstwy wyjściowej i warstwy ukrytej. Warstwa wejściowa odbiera sygnał. W opracowaniu tą warstwą są dane uzyskane w konwersjach przedstawionych w tabelach 2 do 19. Ważną warstwą jest warstwa ukryta, w której odbywają się wszystkie obliczenia. Ostatni wynik w omawianym przypadku pokazuje jedną zmienną - cenę wyrażoną w euro. Przykładowy schemat wielowarstwowego perceptronu przedstawiono na Rys. 2 [8].



Rys. 1. Zależność ceny od wagi i dystansu

Fig. 1. Price dependence on weight and distance




Rys. 2. Schemat perceptronu wielowarstwowego z jedną warstwą ukrytą [8]

Fig. 2. Scheme of a multi-layer perceptron with one hidden layer [8]

Opis poszczególnych elementów nazwy sieci neuronowej przedstawiono graficznie na Rys. 3. Opisano przykład sieci neuronowej z najmniejszym błędem walidacji, który jest również widoczny w tabeli 14.

Zbiór danych jest podzielony na 70% dane treningowe, 15% dane testowe i 15% dane walidacyjne. Sposób dopasowania do podzbioru został wybrany jako losowy. Sieci różnią się liczbą warstw ukrytych, liczbą epok w algorytmie, aktywacją w warstwie ukrytej i wyjściowej.



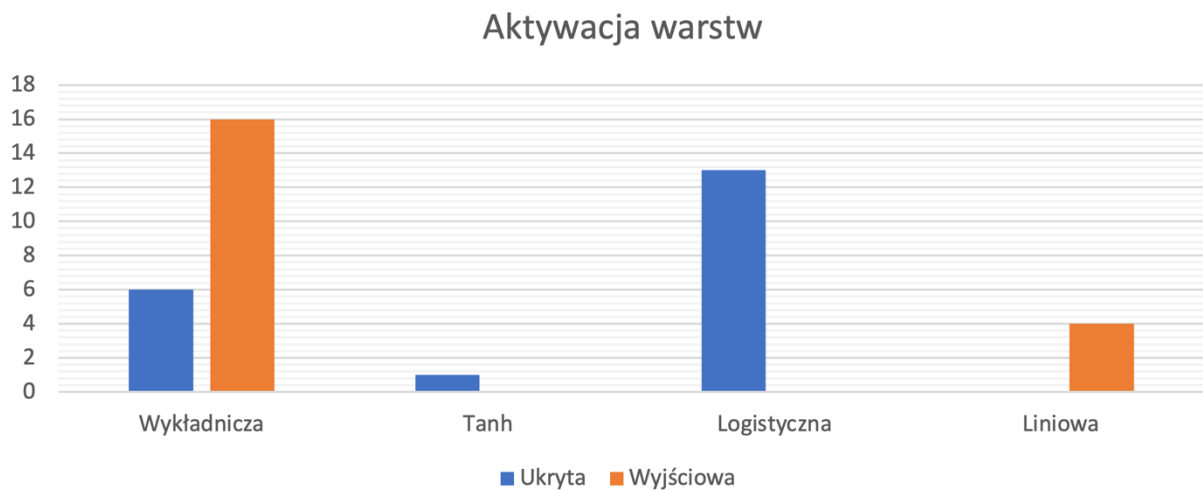
Rys. 3. Opis elementów nazwy sieci neuronowej  
Fig. 3. Overview of the name of the neural network

Tab. 14

Dwadzieścia sieci neuronowych posortowanych od najmniejszego błędu walidacji

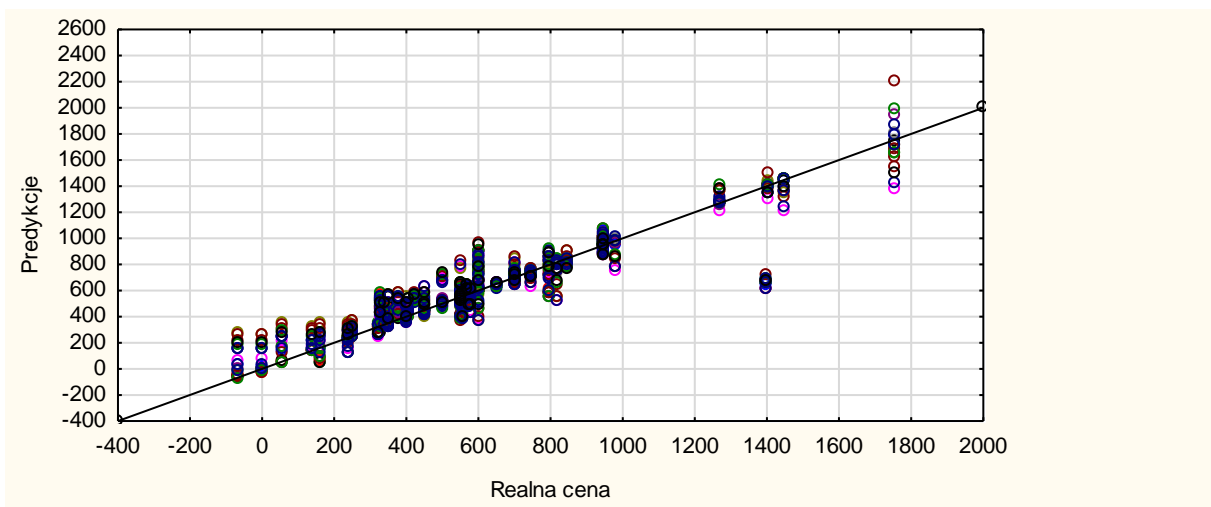
Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Błąd (uczenie)	Błąd (testowanie)	Błąd (walidacja)	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
MLP 60-10-1	1.00	0.69	0.99	230	36666	2947	BFGS 28	SOS	Wykładnicza	Wykładnicza
MLP 60-17-1	1.00	0.70	0.99	139	36339	3075	BFGS 25	SOS	Wykładnicza	Wykładnicza
MLP 60-14-1	1.00	0.63	0.99	69	39728	3240	BFGS 27	SOS	Wykładnicza	Liniowa
MLP 60-16-1	1.00	0.67	0.99	90	37404	3285	BFGS 27	SOS	Wykładnicza	Wykładnicza
MLP 60-8-1	1.00	0.61	0.99	300	41630	3500	BFGS 21	SOS	Wykładnicza	Liniowa
MLP 60-12-1	1.00	0.61	0.99	349	42233	3945	BFGS 21	SOS	Tanh	Wykładnicza
MLP 60-23-1	1.00	0.69	0.99	242	35682	4427	BFGS 21	SOS	Wykładnicza	Wykładnicza
MLP 60-15-1	1.00	0.65	0.98	346	38937	5453	BFGS 30	SOS	Logistyczna	Wykładnicza
MLP 60-15-1	0.97	0.61	0.98	3173	40252	6690	BFGS 13	SOS	Logistyczna	Wykładnicza
MLP 60-19-1	0.97	0.59	0.98	3182	41618	6844	BFGS 13	SOS	Logistyczna	Wykładnicza
MLP 60-14-1	1.00	0.68	0.98	81	36417	7322	BFGS 45	SOS	Logistyczna	Wykładnicza
MLP 60-13-1	0.97	0.60	0.98	2865	40778	7649	BFGS 13	SOS	Logistyczna	Wykładnicza
MLP 60-16-1	0.96	0.61	0.99	4448	40420	8731	BFGS 10	SOS	Logistyczna	Wykładnicza
MLP 60-11-1	0.95	0.58	0.99	5155	42252	10511	BFGS 11	SOS	Logistyczna	Wykładnicza
MLP 60-8-1	0.96	0.59	0.99	4633	42164	11796	BFGS 11	SOS	Logistyczna	Wykładnicza
MLP 60-19-1	0.92	0.61	0.99	7522	41342	11859	BFGS 8	SOS	Logistyczna	Wykładnicza
MLP 60-17-1	0.93	0.72	0.99	7101	35498	11929	BFGS 8	SOS	Logistyczna	Wykładnicza
MLP 60-11-1	0.94	0.61	0.99	5648	41542	12191	BFGS 7	SOS	Logistyczna	Liniowa
MLP 60-12-1	0.94	0.61	0.99	5983	40785	13186	BFGS 7	SOS	Logistyczna	Liniowa
MLP 60-16-1	1.00	0.64	0.99	0	39076	15380	BFGS 162	SOS	Logistyczna	Wykładnicza

Najczęstszą aktywacją w warstwie ukrytej jest logistyczna. W warstwie wyjściowej najczęściej stosowana jest aktywacja wykładnicza. Rozkład typów aktywacji dla warstwy ukrytej i wyjściowej pokazano na Rys. 4.



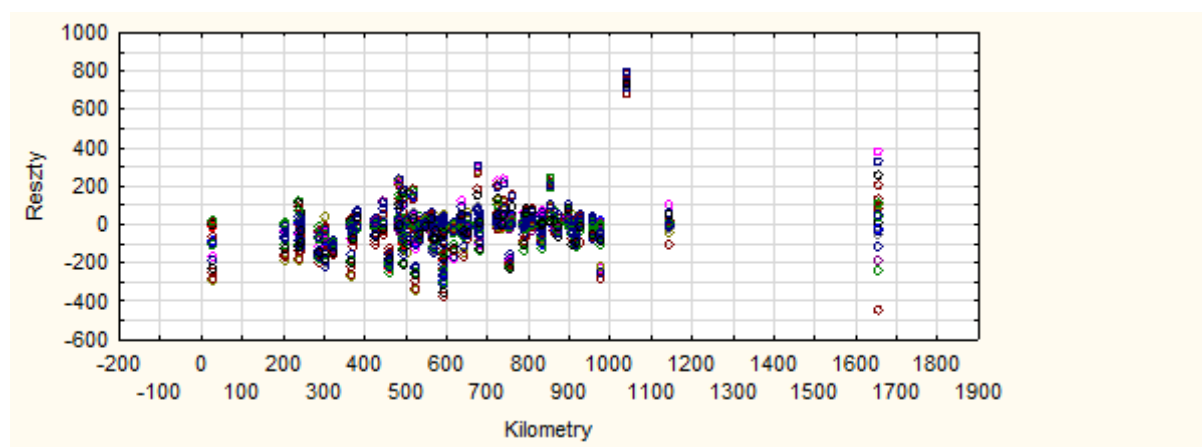
Rys. 4. Rozkład typów aktywacji warstw  
 Fig. 4. The distribution of activation types

Najważniejszą rzeczą w analizie jest sprawdzenie, jak poradził sobie model. Rys. 5 przedstawia wszystkie 20 sieci i ich przewidywania. Dystrybucja jest prawidłowa. Skrajne odchylenia sieci, które jest najgorsze, może nie być wystarczająco dobre. W cenę transportu wliczony jest koszt promu. Cena w modelu to różnica pomiędzy ceną zapłaconą przez klienta a kosztem promu. W przypadku ładunków z miejscem załadunku w Szwecji istnieje sytuacja, w której ostateczna cena jest niższa niż 0.



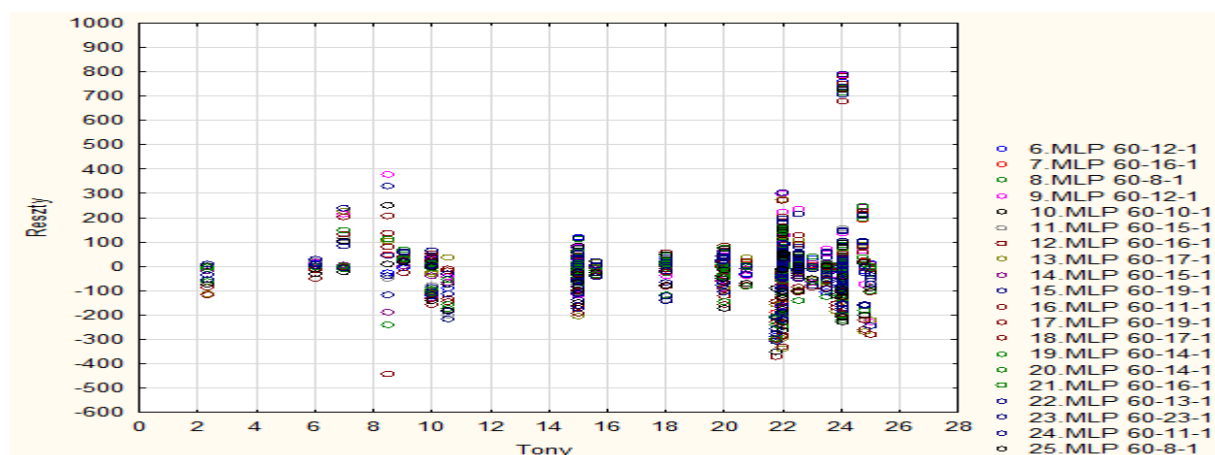
Rys. 5. Prognozy wszystkich sieci neuronowych  
 Fig. 5. Price prediction of neural networks

Rozważania, jak ulepszyć model, można poczynić sprawdzając, z którymi konkretnymi cechami miał on największy problem. Rys. 6 pokazuje, jak to wyglądało z odległości. Wykres przedstawia błąd prognozy w zależności od przebiegu. Model miał podobne błędy w przypadku krótkich i długich transportów.



Rys. 6. Dystrybucja błędów w uzależnieniu od dystansu  
 Fig. 6. Distribution of errors depending from the distance

To samo dotyczy wagi. Model ma podobne błędy dla cięższych i lekkich ładunków. Podsumowując, model dobrze radzi sobie z relacjami między wagą ceny a odległością. Na wykorzystanie może mieć wpływ fakt, że w danych wejściowych liczba kilometrów jest rozłożona na kraje. Jest to ważne ze względu na duże różnice między opłatami. Przedstawiono to na Rys. 7.



Rys. 7. Dystrybucja błędów w zależności od wagi  
 Fig. 7. Distribution of errors depending on the weight

#### 4. TESTOWANIE I WDRAŻANIE MODELU

Dane takie jak jakość modelu i błąd mogą być skomplikowane w rozumieniu. Dla potencjalnych odbiorców, którzy będą chcieli wdrożyć model w codzienną działalność przedsiębiorstwa wartościowa będzie informacja co tak na prawdę daje ten model. Aby przedstawić realną wartość prognozy, zdecydowano się na eksperyment. Dane zostały zebrane z giełdy transportowej i przedstawione poniżej w tabeli 15.



Tab. 15

Dane wejściowe do testu

ID	DE_KM	PL_KM	CZ_KM	COD_LP	Data początku załadunku	Data końca załadunku	COD_DP	Data początku rozładunku	Data końca rozładunku	Typ pojazdu	Typ zabudowy	Załadunek Rozładunek	Typ towaru	Euro	LDM [m]	Waga [t]
1	119.900		275.300	CZ25090	2021-04-28	2021-04-28	DE99867	2021-04-29	2021-04-29	Pojazd z przyczepą, Ciągnik z naczepą	Plandeka	Tył, Bok	Inne	600.00	13.60	24.00
2	518.800	405.500		DE35510	2021-04-26	2021-04-26	PL97300	2021-04-27	2021-04-28	Pojazd z przyczepą, Ciągnik z naczepą	Plandeka	Tył, Bok	Inne	650.00	13.60	15.00
3	445.200	489.600		DE34117	2021-04-26	2021-04-26	PL05075	2021-04-27	2021-04-27	Pojazd z przyczepą, Ciągnik z naczepą	Plandeka, Firanka, Mega	Tył, Bok	Inne	730.00	13.60	14.80
4	238.300	213.400		PL63025	2021-04-26	2021-04-26	DE01662	2021-04-27	2021-04-27	Pojazd z przyczepą, Ciągnik z naczepą	Plandeka, Chłodnia, Firanka	tył	Inne	450.00	13.60	14.00
5		340.600	150.400	PL41300	2021-04-27	2021-04-29	CZ19017	2021-04-28	2021-04-30	Pojazd z przyczepą, Ciągnik z naczepą	Plandeka, Chłodnia, Firanka	Tył, Bok	Inne	580.00	13.60	24.00

Następnie dane zostały przekonwertowane i wprowadzone do modelu. Wyszkolone sieci neuronowe podały prognozy cenowe. Wyniki przedstawiono w tabeli 16.

Tab. 16

Predykcje sieci neuronowych

Realna cena	ID sieci neuronowej																								
	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25					
	Predykcje cen																								
350.00	374.04	326.56	436.21	344.20	351.22	392.20	373.02	368.62	339.97	385.21	449.45	397.75	315.07	371.42	390.82	422.92	390.09	404.50	366.59	431.63					
600.00	518.56	483.71	589.22	342.17	618.56	364.37	437.23	426.59	423.45	360.42	411.12	403.51	458.26	558.14	472.43	381.19	368.91	596.87	352.88	393.49					
900.00	576.91	727.24	737.47	360.07	887.36	432.85	518.81	444.79	560.48	436.40	452.04	431.11	666.93	575.91	601.57	448.30	459.79	664.67	365.65	457.68					
700.00	610.05	613.41	701.43	443.16	698.10	521.08	455.28	379.46	636.64	524.41	532.21	416.58	690.18	686.20	663.09	561.90	543.43	651.60	461.57	550.72					
550.00	568.17	484.81	552.77	438.38	576.85	447.34	423.96	357.28	564.06	442.22	488.21	380.10	542.23	542.36	616.41	482.53	450.47	575.59	478.67	482.13					

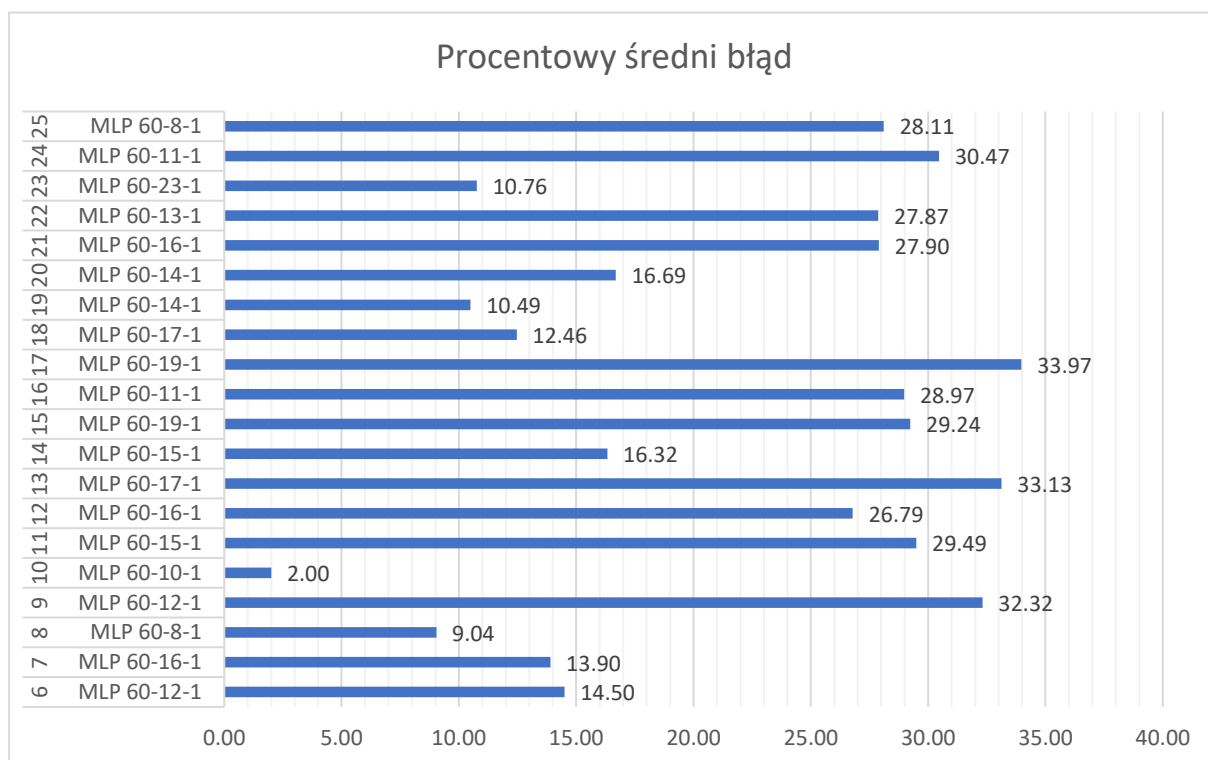
Tabela 17 pokazuje procentowy błąd poszczególnych sieci neuronowych podczas prognozowania ceny poszczególnych ofert.

Tab. 17

Procentowy błąd poszczególnych sieci neuronowych

Realna cena	ID sieci neuronowej																								
	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25					
	Procentowy błąd																								
350.00	6.87	6.70	24.63	1.66	0.35	12.06	6.58	5.32	2.86	10.06	28.41	13.64	9.98	6.12	11.66	20.83	11.45	15.57	4.74	23.32					
600.00	13.57	19.38	1.80	42.97	3.09	39.27	27.13	28.90	29.43	39.93	31.48	32.75	23.62	6.98	21.26	36.47	38.52	0.52	41.19	34.42					
900.00	35.90	19.20	18.06	59.99	1.40	51.91	42.35	50.58	37.72	51.51	49.77	52.10	25.90	36.01	33.16	50.19	48.91	26.15	59.37	49.15					
700.00	12.85	12.37	0.20	36.69	0.27	25.56	34.96	45.79	9.05	25.08	23.97	40.49	1.40	1.97	5.27	19.73	22.37	6.91	34.06	21.33					
550.00	3.30	11.85	0.50	20.30	4.88	18.66	22.92	35.04	2.56	19.60	11.23	30.89	1.41	1.39	12.07	12.27	18.10	4.65	12.97	12.34					

Na koniec obliczono średnią prognoz poszczególnych sieci neuronowych i pokazano na Rys. 8. Błąd najlepszego wynosi średnio 2%. Dwa procenty w predykcji to dużo lub mało w zależności od tego co się przewiduje. Ocenia się, że do predykcji cen w transporcie jest to wystarczająco dobre.



Rys. 8. Porównanie średniego procentowego błędu wszystkich sieci neuronowych

Fig. 8. Comparison of the percentage of mean prediction errors of the neural network

## 5. WNIOSKI

Sztuczna inteligencja to przyszłościowe rozwiązanie. Służy do rozwiązywania problemów w wielu obszarach. Każdego dnia sprawia, że życie jest łatwiejsze i lepsze. Sieci neuronowe pomagają rozwiązywać wiele złożonych problemów, takich jak prognozowanie cen ropy lub zużycia paliwa przez statki. Zastosowanie rozwiązań sztucznych sieci neuronowych rośnie ze względu na wzrost mocy obliczeniowej. Potencjał sztucznej inteligencji dostrzegają rządy i jednostki naukowe. Sztuczna inteligencja odgrywa ważną rolę w strategiach i planach rozwoju.

Potwierdzono postawioną główną tezę. Sieci neuronowe mogą być z powodzeniem wykorzystywane do prognozowania cen w transporcie drogowym. Jest to rozwiązanie, które z powodzeniem można wdrożyć w każdej firmie związanej z transportem drogowym.

Giełdy transportowe i platformy przetargowe mogą oferować swoim użytkownikom dodatkową funkcję, np. sprawdzanie szacowanej ceny na podstawie wcześniej złożonych ofert. Giełdy ładunków często mają możliwość zawierania transakcji między użytkownikami. Ciekawym rozwiązaniem będzie rozróżnienie prognoz opartych wyłącznie na ofertach a faktycznie zawartymi transakcjami.

Często spedytorzy muszą składać oferty swoim klientom przez cały rok. Znajomość prognoz na cały rok ułatwi wycenę usługi. Na wolnym rynku może się okazać, że w miesiącach z większym popytem na usługi transportowe będą musieli więcej płacić podwykonawcom. Wszystkie te dane należy wziąć pod uwagę, zwłaszcza gdy klient żąda ceny za cały rok.

Firmy transportowe starają się maksymalnie ograniczyć puste przebiegi. To działanie jest korzystne zarówno ze względów ekonomicznych, jak i ekologicznych. Przewoźnik składający ofertę na transport

eksportowy musi mieć informację, jaką cenę może liczyć na dany typ konstrukcji na importowanym ładunku w danym okresie. Analiza odwrotnych opłat za pomocą sieci neuronowych bardzo pomoże.

Testowany model sprawował się podobnie, niezależnie od długości trasy i wagi towaru. Przedstawione w artykule wyniki i metody można z powodzeniem zastosować w kolejnych badaniach.

## Literatura

1. European countries by region and method of charging. Available at: <http://www.tolls.eu/> (accessed: 2021-04-24)
2. Gesetze im Internet. Available at: <http://gesetze-im-internet.de/milog> (accessed: 2021-04-17)
3. Tadeusiewicz, S. *Sieci Neuronowe*. [In. Polish: *Neural Networks*]. 1993.
4. Bal Beşikçi, E. & Arslan, O. & Turan, O. & Ölçer, A.I. An artificial neural network based decision support system for energy efficient ship operations. *Computers & Operations Research*. 2016. Volume 66. P. 393-401.
5. Mohamed M. Mostafa & Ahmed A. El-Masry. Oil price forecasting using gene expression programming and artificial neural networks. *Economic Modelling*. 2013. Volume 54. P. 340-53.
6. Resolution 196 the council of minister of December 28, 2020 on the establishment of the "Policy for the development of artificial intelligence in Poland from 2020".
7. Sieci Neuronowe. [In Polish: Neural Networks]. Available at: [https://www.statsoft.pl/textbook/stathome\\_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstneunet.html](https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstneunet.html) (accessed: 2021-04-22).
8. Abirami, S. & Chitra, P. Multilayer Perceptron. *Advances in Computers*. 2020. Volume 117. Issue 1. P. 339-368.