

Arkadiusz Jóźwiak

Wojskowa Akademia Techniczna, Wydział Logistyki, Instytut Logistyki

Andrzej Świdorski

Instytut Transportu Samochodowego

ALGORYTMY SZTUCZNEJ INTELIGENCJI W LOGISTYCE

Rękopis dostarczono: maj 2017

Streszczenie: W artykule przedstawiono zastosowanie sztucznej inteligencji w logistyce. Jako przykład, omówiono neuronowe modelowanie oceny usług transportowych i wieloaspektowość tego zagadnienia. Zaproponowano metodę oceny, wykorzystującą sztuczne sieci neuronowe w oparciu o perceptron wielowarstwowy jednokierunkowy wykorzystujący algorytm wstecznej propagacji błędu. Podstawę weryfikacji metody stanowiły badania eksperymentalne przeprowadzone w firmie produkcyjnej branży spożywczej. Uzyskane wyniki na poziomie 95-99% prawdopodobieństwa potwierdziły przydatność sieci neuronowych do oceny usług transportowych. Odniesiono się również do innych obszarów zastosowań sztucznej inteligencji w logistyce.

Słowa kluczowe: sztuczna inteligencja, sieci neuronowe, ocena usług transportowych

1. WSTĘP

Logistyka, w ostatnich latach, należy do najbardziej dynamicznie rozwijających się grup zawodów. Wg portalu www.pracuj.pl, w roku 2015 kluczowe wzrosty ofert pracy odnotowano w budownictwie (15%), w przemyśle lekkim (12,5%) oraz w transporcie i logistyce (12,4%). Natomiast w 2016 r. największy wzrost zapotrzebowań na specjalistów odnotowały takie obszary, jak: obsługa klienta (23%), logistyka (21%) i produkcja (16%), do której dołączane są kolejne moduły przedsiębiorstwa, tj.: marketing czy finanse [1]. Można wnioskować, że przez najbliższe lata, rynek pracy będzie rozwijał się pod dyktando wymienionych działów. Wspólnym mianownikiem jest transport, jako istotny element gospodarki i życia społecznego. Usługi transportowe są czynnikiem intensyfikującym postęp i kooperację w obszarze społecznym, przemysłowym i gospodarczym [2]. Usługi kurierskie są jednym z najszybciej rozwijających się sektorów transportu towarowego na świecie [9]. Dodatkowo, zauważyć można ogólne trendy zachodzące w logistyce, tj.: globalizacja gospodarki (przepływ towarów, kapitału i informacji w skali światowej),

personalizacja (produkty i usługi „szyte na miarę” pod potrzeby indywidualnego klienta), wzrost świadomości ekologicznej (ochrona środowiska, logistyka odpadów) i rozwój technologii informacyjnych (nowe narzędzia do zarządzania, oceny, czy wspomagania podjęcia decyzji). Każdy z tych aspektów posiada wiele wspólnych cech, ale nie mniej również cech przeciwstawnych. Dlatego pożądaną są metody, narzędzia i mechanizmy, które potrafią w sposób wyważony uwzględnić wszystkie te czynniki, głównie podczas oceny procesów logistycznych. Przydatnym narzędziem może być sztuczna inteligencja, która znajduje coraz szersze zastosowanie w różnych segmentach rynku, w tym również w logistyce. Problemy sztucznej inteligencji rozwiązuje inteligencja obliczeniowa (ang. computational intelligence), która korzysta z takich technik, jak [5]: sieci neuronowe, logika rozmyta, algorytmy ewolucyjne, zbiory przybliżone, zmienne niepewne, metody probalistyczne.

Celem artykułu jest przedstawienie możliwości wykorzystania wybranych zagadnień sztucznej inteligencji w logistyce oraz zaprezentowanie wyników badań własnych nad zastosowaniem sztucznych sieci neuronowych do oceny usług logistycznych na przykładzie usług transportowych (UT).

W artykule wykorzystano następujące metody badawcze: dedukcję (do osądu obserwacji i zdarzeń), analizę (do określenia kryteriów i charakterystyk oceny), syntezę systemową (przydatną we wnioskowaniu) oraz modelowanie matematyczne wykorzystujące sztuczne sieci neuronowe.

2. ISTOTA OCENY USŁUG TRANSPORTOWYCH

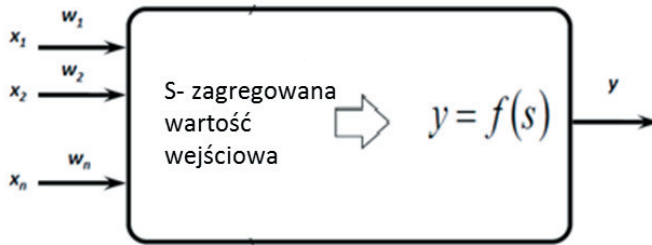
Na przestrzeni ostatnich kilkunastu lat obserwuje się rozwój transportu i będące jego efektem zmiany wielkości, zakresu i struktury świadczonych usług transportowych. Jest to też efekt zarówno strategii rozwoju gospodarczego, jak i przyjętej polityki transportowej państwa. Jednakże nie uniknięto błędów. W wielu obszarach można było zauważyć: zbyt niskie nakłady na rozwój transportu, brak konsekwentnych działań w realizowaniu programów, rozproszenie nakładów i brak kompleksowości. Dlatego rozwój transportu w Polsce był opóźniony w stosunku do popytu, co objawiało się: opóźnieniem lub ograniczeniem rozwoju nowych technologii transportowych, negatywnymi zmianami strukturalnymi w transporcie, czy w końcu obniżeniem jakości UT.

Ocena jakości pełni różne funkcje, m.in. ewaluacyjną (ocenia się dotychczasowy i obecny poziom), rozwojową (ocenia się potencjał rozwojowy), informacyjną (dostarcza obiektywnej informacji) czy decyzyjną (wspomaga podejmowanie decyzji). W literaturze przedmiotu badań nie ma jednoznacznie zdefiniowanego pojęcia jakości UT. Istnieje wiele definicji samej jakości. Na potrzeby artykułu przyjęto, że jakość UT, to stopień spełnienia wymagań opisanych charakterystykami jakości [6]. Przyjęto też, że charakterystyki są elementami opisującymi kryteria oceny. Wybór kryteriów oceny może być różny, zależny od potrzeb i celu badań. Głównymi determinantami wyboru kryteriów jest cel, jaki chce się osiągnąć po dokonaniu oceny lub informacja, którą chce się uzyskać na podstawie wyniku oceny.

Zasadniczym problemem przy wyborze kryteriów oceny UT, jest jej wieloaspektowość. Poza zasadniczymi kryteriami oceny (tj.: koszt, terminowość, szeroko rozumiana jakość, zwroty z tytułu uszkodzenia ładunku w transporcie, czy procedura obsługi), dochodzą też inne: rodzaj i zasięg działania usługi, wykorzystany środek transportu, ochrona środowiska, czy rodzaj wykorzystywanej technologii transportowej, itp.

3. ISTOTA MODELOWANIA NEURONOWEGO

Sztuczne sieci neuronowe (SSN) oparte są na budowie mózgu i układzie nerwowym człowieka. Zasadniczym elementem tych układów są komórki nerwowe. Dlatego SSN tworzą tzw. neurony (elementy przetwarzające dane), które swoją strukturą są próbą odzwierciedlenia budowy komórki nerwowej. Istota modelowania neuronowego polega na poszukiwaniu modelu matematycznego, wykorzystując sygnały wejściowe x_1, x_2, \dots, x_n każdego neuronu i przypisane im wagi w_1, w_2, \dots, w_n , celem poszukiwania sygnału wyjściowego y (rys. 1).




Rys. 1. Model neuronu
(Źródło: [4])

Wewnątrz każdego neuronu mają zastosowanie dwie podstawowe funkcje:

- funkcja agregacji danych, która wyznacza wartość wejściową wszystkich sygnałów wejściowych;
- funkcja aktywacji $y=f(s)$, która wyznacza wartości wyjściowe neuronu.

Sposoby łączenia neuronów, funkcje agregacji i aktywacji determinują rodzaj i strukturę sieci neuronowej. Najbardziej popularną siecią jest sieć jednokierunkowa - perceptron wielowarstwowy (rys. 2).

Neurony ułożone są w warstwach: wejściowej, ukrytych i wyjściowej. Połączone są ze sobą na zasadzie każdy z każdym między warstwami, natomiast w ogóle nie komunikują się ze sobą w danych warstwach. Perceptron jest najczęściej stosowanym typem sieci neuronowej. Sieć ta wymaga iteracyjnego uczenia, które jest czasochłonne, natomiast raz nauczona działa szybko i w większości przypadków uzyskuje się lepsze wyniki niż w innych sieciach. O stopniu złożoności sieci decyduje liczba warstw ukrytych i liczba neuronów.



Rys. 2. Schemat sieci jednokierunkowej- perceptronu wielowarstwowego
(Źródło: opracowanie własne)

Kolejnym czynnikiem decydującym o charakterze sieci jest algorytm jej uczenia. W praktyce mamy do czynienia z algorytmami: z nauczycielem (gdzie wskazuję się pożądaną wartość wyjściową jako wzorcową) i bez nauczyciela (sieć sama uzyskuje wyniki końcowe na podstawie analizy relacji między danymi wejściowymi). W literaturze przedmiotu badań istnieje wiele zdefiniowanych algorytmów uczenia. Wyróżnić można [5]:

- algorytm wstecznej propagacji błędów;
- algorytm zmiennej metryki;
- algorytm Levenberga-Marquardta;
- rekurencyjna metoda najmniejszych kwadratów;
- algorytm WTA (*ang. winner take all*);
- algorytmy WTM (*ang. winner take more*);

z których najczęściej wykorzystywanym jest algorytm wstecznej propagacji błędów [4], uczący sieci jednokierunkowe wielowarstwowe, wykorzystujący modyfikację wag wszystkich sygnałów wejściowych wielowarstwowej sieci neuronowej do osiągnięcia minimum miary błędów przy określaniu tych wag.

4. WYNIKI BADAŃ WŁASNYCH

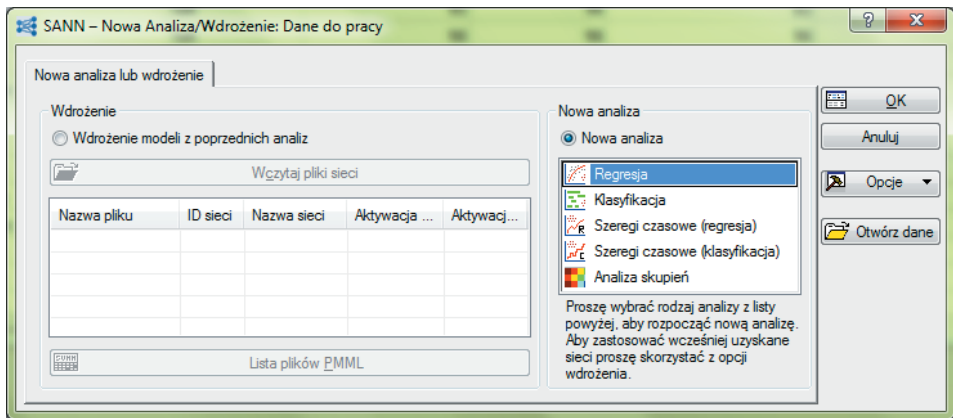
Badania dotyczące możliwości wykorzystania algorytmów sztucznej inteligencji w logistyce na przykładzie oceny usług transportowych przeprowadzono w firmie produkcyjnej, zajmującej się produkcją wyrobów mleczarskich. Jednym z głównych procesów logistycznych w tej firmie, jest proces zakupów i codziennego odbioru i transportu mleka od kilkuset dostawców do zakładu produkcyjnego. Celem badań było opracowanie metody oceny usług transportowych realizowanych przez przewoźników i jej weryfikacja w praktyce. Pierwszym zadaniem było zdefiniowanie kryteriów oceny i opisujących ich charakterystyk. Po przeanalizowaniu potrzeb firmy, zdefiniowano pięć podstawowych kryteriów:

1. Bezpieczeństwo przewozu ładunku, opisane charakterystykami: zachowanie warunków temperaturowych przewozu, stan plomby na cysternie, czystość środka transportu, posiadane dokumenty obowiązujące przy transporcie mleka.
2. Planowanie tras, opisane charakterystykami: współczynnik napełnienia cysterny, realizacja trasy, prognozowalność popytu, dyspozycyjność kierowców.
3. Terminowość, opisana charakterystykami: czas odbioru u dostawców, czas planowanej trasy, czas rozpoczęcia usługi.
4. Jakość odbioru, opisana charakterystykami: pomiar u dostawcy, braki transportowe, prawidłowość pobierania prób mikrobiologicznych, higiena urządzeń do poboru prób.
5. Ocena eksploatacyjna środków transportowych, opisana charakterystykami: nieuszkodzalność, obsługiwalność, wiek pojazdu i stan technicznych pojazdu.

Przy tak zdefiniowanych kryteriach i charakterystykach oceny usług transportowych zebrano dane z bieżącej eksploatacji, które stanowiły punkt wyjścia do rozpoczęcia badań. Przykładowe dane przedstawiono w tabelicy 1. Są to dane z oceny przeprowadzonej przez ekspertów firmy: dyspozytora transportu, kierownika wydziału produkcji ogólnej/ działu odbieralni, kierownika laboratorium badania mleka/ laboratorium odbieralni, kierownika działu transportu.

Jak już wspomniano, dane przedstawione w tabeli 1, to jedynie przykład. Do uczenia sieci wykorzystano ok. 250 danych zebranych z bieżącej eksploatacji w ciągu ostatnich 2 lat.

Dane, przykładowo przedstawione w tabeli 1, wykorzystano do zbudowania i nauczenia sieci neuronowej, która wykorzystywana będzie do dokonywania bieżących ocen usług transportowych, z wykorzystaniem programu komputerowego Statistica 12. W pierwszej kolejności określono rodzaj analizy. W tym przypadku była to „regresja” (rys. 3).



Rys. 3. Wybór rodzaju analizy

(Źródło: opracowanie własne z wykorzystaniem programu Statistica 12)

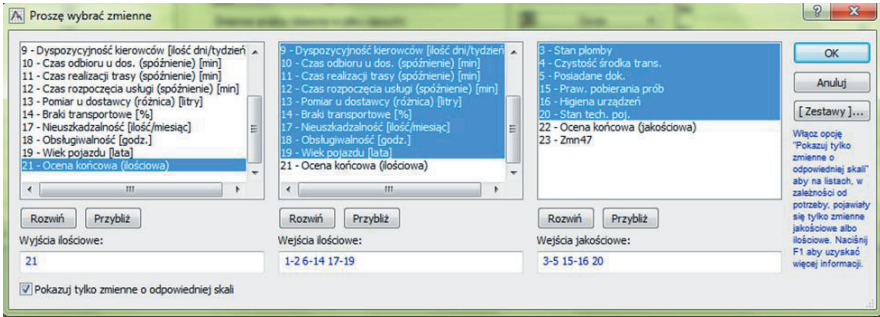
Tablica 1

Kryteria oceny usług transportowych

№	1					2				3				4				5				Ocena końcowa
	Bezpieczeństwo przewozu ładunku					Planowanie tras				Terminowość				Jakość odbioru				Ocena eksploatacyjna środków transportowych				
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19			
	zachowanie warunków temperatury przewozu	stan pompy na systemie	czystość środka transportu	dokumenty obowiązuje przy transporcie mleka	Wsłóczytnik napełnienia systemu	Realizacja przebiegu trasy	Prognozowalność popytu	Dyspozycyjność kierowców	czas odbioru u dostawców (spóźnienie)	czas realizacji wyznaczonej trasy (spóźnienie)	czas rozpoczęcia usługi (spóźnienie)	miar u dostawcy (różnica)	braki transportowe	prawidłowość pobierania prób mikrobiologicznych	higiena urządzeń do poboru prób	nieszkadzalność	obsługwalność	wiek pojazdu	Stan techniczny pojazdu			
	Wartość [stopnie C]	bd, pn, pz	pc, pnc, pb	tak, nie	100% >94	w %	w %	7,6,5,4	min	min	min	litry	%	tak, nie	tak, nie	ilość uszkodzeń	ilość godz.	w latach	bdb, zad, nzb			
1	4	bd	pc	tak	95	99	82	6	10	30	10	1	1	tak	tak	0	0	1	bdb	0,902		
2	7	bd	pc	tak	96	105	90	5	25	30	10	4	2	tak	tak	0	0	2	bdb	0,888		
3	8	bd	pc	tak	93	106	81	7	25	40	10	5	1	tak	tak	0	0	2	bdb	0,816		
4	3	bd	pc	tak	94	98	82	7	15	30	10	6	1	tak	tak	0	0	3	bdb	0,885		
5	4	9	bd	pc	96	101	86	7	40	70	10	8	3	tak	tak	1	1	5	bdb	0,760		
6	5	9	bd	pc	93	106	78	7	10	30	10	8	3	tak	tak	0	0	6	bdb	0,803		
7	6	5	bd	pc	91	108	78	7	20	30	15	8	3	tak	tak	1	1	6	bdb	0,732		
8	7	2	bd	pc	95	100	77	7	10	30	10	10	4	tak	tak	0	0	7	zad	0,802		
9	7	5	bd	pc	95	98	75	7	10	30	10	13	4	tak	tak	0	0	7	zad	0,804		
10	8	6	bd	pc	96	99	85	5	45	90	25	12	3	tak	tak	0	0	8	zad	0,629		
11	8	9	bd	pc	98	95	93	7	45	80	25	10	3	tak	tak	1	1	8	zad	0,655		
12	9	8	bd	pnc	94	101	82	7	10	30	10	6	3	nie	tak	0	0	8	bdb	0,849		
13	10	6	bd	pc	94	100	75	7	15	30	10	7	4	tak	tak	0	0	11	nzb	0,784		
14	11	8	bd	pc	96	96	84	7	10	30	10	9	4	tak	tak	0	0	11	zad	0,819		
15	11	9	bd	pc	91	96	76	7	10	30	10	9	4	tak	tak	0	0	11	zad	0,773		
16	12	6	bd	pnc	96	99	86	7	15	30	10	10	4	tak	nie	0	0	12	zad	0,820		
17	12	9	bd	pc	94	98	82	7	15	30	10	9	3	tak	tak	0	0	12	zad	0,808		
18	13	6	bd	pc	95	98	81	7	15	30	10	9	3	tak	tak	0	0	13	zad	0,796		
19	14	1	bd	pc	93	105	78	7	20	30	10	9	3	tak	tak	0	0	13	zad	0,746		

Źródło: opracowanie własne.

Następnie dokonano wyboru danych wejściowych - ilościowych i jakościowych oraz danych wyjściowych ilościowych (rys. 4).

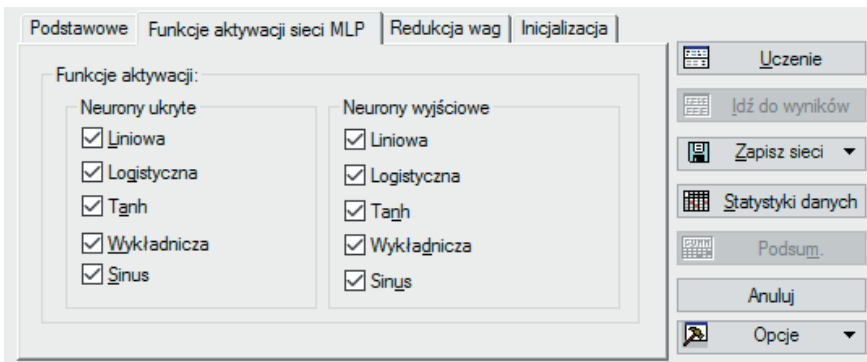


Rys. 4. Wybór danych ilościowych i jakościowych do uczenia sieci neuronowej
(Źródło: opracowanie własne z wykorzystaniem programu Statistica 12)

Wraz z określeniem danych wejściowych, zdefiniowano wielkość zbioru uczącego. Określono zatem, iż 80% danych (spośród 250) stanowić będzie zbiór uczący wykorzystywany do modyfikacji wag, 10% - zbiór testowy przeznaczony do bieżącego monitorowania procesu uczenia i 10% - zbiór walidacyjny do oceny jakości sieci po zakończeniu uczenia.

W kolejnym kroku określono podstawowe parametry sieci (rys. 5):

- rodzaj wykorzystanej sieci (perceptron wielowarstwowy - MLP),
- liczbę neuronów ukrytych,
- funkcję aktywacji (liniową, logistyczną, tanh, wykładniczą, sinus).



Rys. 5. Wybór parametrów sieci neuronowej
(Źródło: opracowanie własne z wykorzystaniem programu Statistica 12)

Wykorzystując wszystkie dostępne metody funkcji aktywacji dokonano procesu uczenia sieci. Przykładowe wyniki tego procesu przedstawiono w tabelicy 2.

Tablica 2

Przykładowe wyniki procesu uczenia sieci neuronowej

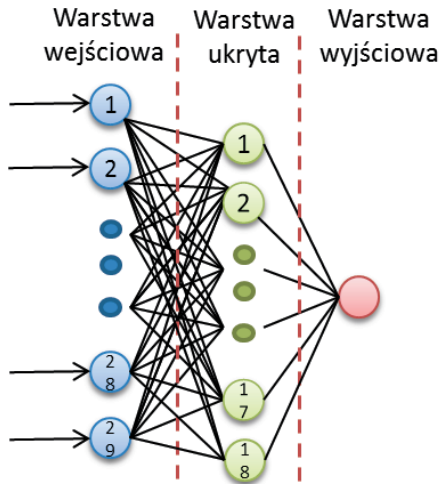
ID	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Błąd uczenia	Błąd testowania	Błąd walidacji	Algorytm uczenia	Funkcja błędu	Aktywacja ukryte	Aktywacja wyjściowe
53	MLP 29-6-1	0,931549	0,920999	0,866019	0,000514	0,000570	0,000824	BFGS 22	SOS	Sinus	Logistyczna
31	MLP 29-12-1	0,947748	0,927007	0,824608	0,000394	0,000433	0,000700	BFGS 5	SOS	Liniowa	Liniowa
35	MLP 29-11-1	0,954764	0,911863	0,831112	0,000292	0,000557	0,000525	BFGS 7	SOS	Liniowa	Wykładnicza
34	MLP 29-18-1	0,962161	0,955815	0,702086	0,000236	0,000336	0,001451	BFGS 17	SOS	Liniowa	Tanh
54	MLP 29-8-1	0,964718	0,955733	0,830308	0,000226	0,000358	0,000741	BFGS 24	SOS	Sinus	Tanh
51	MLP 29-7-1	0,966174	0,953364	0,688744	0,000215	0,000311	0,001413	BFGS 34	SOS	Wykładnicza	Sinus
36	MLP 29-11-1	0,970437	0,947599	0,668187	0,000183	0,000402	0,001801	BFGS 15	SOS	Liniowa	Sinus
41	MLP 29-11-1	0,970514	0,930567	0,730330	0,000184	0,000523	0,001183	BFGS 29	SOS	Logistyczna	Sinus
33	MLP 29-12-1	0,971387	0,949473	0,764607	0,000178	0,000390	0,001173	BFGS 13	SOS	Liniowa	Logistyczna
39	MLP 29-17-1	0,971665	0,953356	0,713231	0,000180	0,000353	0,001577	BFGS 13	SOS	Logistyczna	Tanh
56	MLP 29-16-1	0,975206	0,944511	0,715905	0,000155	0,000417	0,001473	BFGS 15	SOS	Sinus	Sinus
55	MLP 29-9-1	0,976758	0,941768	0,854456	0,000148	0,000396	0,000673	BFGS 46	SOS	Sinus	Wykładnicza
45	MLP 29-6-1	0,983741	0,954595	0,791330	0,000102	0,000319	0,000959	BFGS 35	SOS	Tanh	Wykładnicza
52	MLP 29-9-1	0,984411	0,954591	0,822080	0,000097	0,000302	0,000591	BFGS 36	SOS	Sinus	Liniowa
44	MLP 29-9-1	0,986418	0,938580	0,805363	0,000085	0,000378	0,000702	BFGS 37	SOS	Tanh	Tanh
50	MLP 29-7-1	0,988208	0,950988	0,779942	0,000074	0,000304	0,000900	BFGS 52	SOS	Wykładnicza	Wykładnicza
40	MLP 29-13-1	0,989877	0,965548	0,768630	0,000063	0,000220	0,001005	BFGS 77	SOS	Logistyczna	Wykładnicza
49	MLP 29-13-1	0,990123	0,967700	0,781791	0,000062	0,000210	0,000886	BFGS 62	SOS	Wykładnicza	Tanh
37	MLP 29-14-1	0,990225	0,941406	0,820885	0,000061	0,000382	0,000641	BFGS 72	SOS	Logistyczna	Liniowa
48	MLP 29-12-1	0,991031	0,954335	0,844501	0,000056	0,000282	0,000597	BFGS 43	SOS	Wykładnicza	Logistyczna
46	MLP 29-8-1	0,992197	0,949121	0,696255	0,000049	0,000315	0,001242	BFGS 68	SOS	Tanh	Sinus
43	MLP 29-17-1	0,992339	0,956261	0,854677	0,000048	0,000276	0,000620	BFGS 69	SOS	Tanh	Logistyczna
47	MLP 29-7-1	0,993022	0,957511	0,761694	0,000044	0,000255	0,001093	BFGS 71	SOS	Wykładnicza	Liniowa
42	MLP 29-18-1	0,993157	0,967570	0,839853	0,000043	0,000204	0,000529	BFGS 68	SOS	Tanh	Liniowa
38	MLP 29-14-1	0,993213	0,955366	0,750477	0,000043	0,000295	0,001342	BFGS 98	SOS	Logistyczna	Logistyczna

Źródło: Opracowanie własne

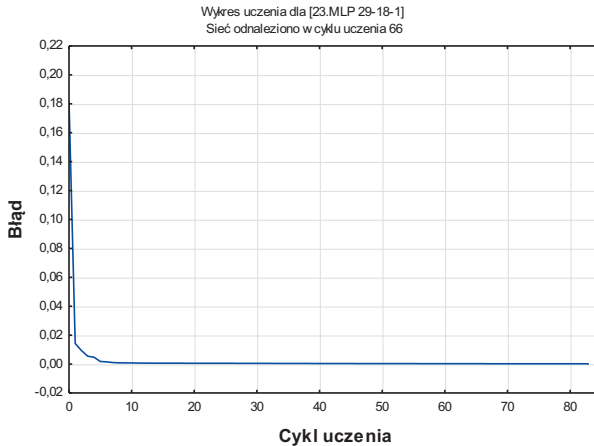
Kolorem niebieskim oznaczono sieci, które wykazywały najniższą jakość na podstawie zbioru uczącego, natomiast kolorem czerwonym najwyższą jakość sięgającą prawie 99,5%. Należy jednak zauważyć, że jakość zbioru walidacyjnego nie jest zbieżna z jakością zbioru uczącego. Dlatego, za najlepszą sieć uznano MLP 29-18-1, oznaczona kolorem żółtym. Jakość zbioru uczącego wyniosła 0,99%, natomiast jakość zbioru walidacyjnego 0,84%. Funkcją agregującą dane w neuronie została funkcja tangens, natomiast funkcja wyjścia przyjęła postać funkcji liniowej.

Przy tak określonych parametrach i przeprowadzeniu procesu uczenia, struktura najlepszej sieci przyjęła postać MLP 29-18-1, co oznacza 29 neuronów w warstwie wejściowej, 18 neuronów w warstwie ukrytej i 1 neuron w warstwie wyjściowej (rys. 6).

O pozytywnym wyniku uczenia sieci neuronowej świadczy m.in. wykres uczenia, z którego wynika, że najlepszą strukturę sieci odnaleziono w 66 cyklu uczenia, który wynosi 0.002 (rys. 7).



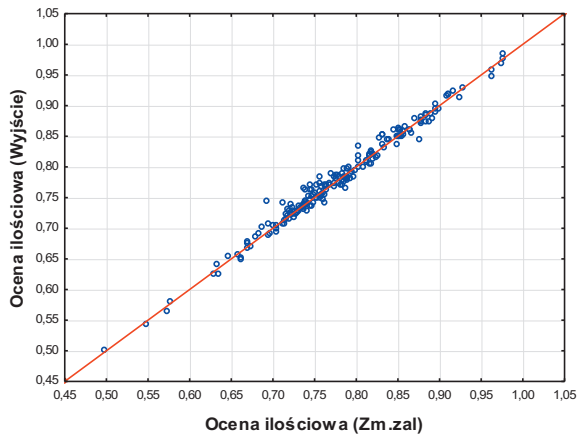
Rys. 6. Struktura badanej sieci MLP 29-18-1
(Źródło: opracowanie własne z wykorzystaniem programu Statistica 12)



Rys. 7. Wykres uczenia sieci MLP 29-18-1
(Źródło: opracowanie własne z wykorzystaniem programu Statistica 12)

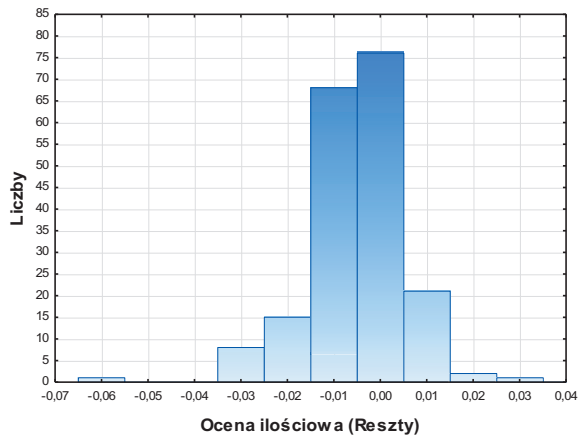
Również wykres rozrzutu zmiennej zależnej i jej predykcji świadczy o pozytywnym wyniku uczenia sieci (rys. 8).

Z wykresu można odczytać, jak dokładnie sygnały wyjściowe sieci neuronowej (w tym przypadku przewidywana ocena) odzwierciedla rzeczywistą wartość zmiennej wyjściowej (oceny wykorzystane do uczenia sieci).



Rys. 8. Wykres rozrzutu zmiennej zależnej sieci neuronowej MLP 29-18-1
(Źródło: opracowanie własne z wykorzystaniem programu Statistica 12)


Kolejną istotną cechą badanej sieci neuronowej jest rozkład reszt, czyli różnic między zmienną wyjściową a jej predykcją (rys. 9).



Rys. 9. Rozkład reszt sieci neuronowej MLP 29-18-1
(Źródło: Opracowanie własne)

Z histogramu można odczytać, że reszty są rozłożone normalnie wokół zera z naciskiem na wartości ujemne, co jest zgodne z ogólnym założeniem normalności szumu zawartego w danych. Im szersze histogramy, tym rozrzut danych jest większy.

Globalna analiza wrażliwości wygenerowana przez program odzwierciedla istotność (ważność) poszczególnych zmiennych wejściowych sieci na sygnał wyjściowy- ocenę ilościową (rys. 10).



Rys. 10. Globalna analiza wrażliwości dla sieci neuronowej MLP 29-18-1
(Źródło: Opracowanie własne)

Iloraz błędu sieci bez danej zmiennej do błędu z kompletem wyjść mniejszy od 1 oznacza, że dany czynnik (aspekt) nie ma wpływu na wynik końcowy sieci, można również powiedzieć, że sieć działałaby lepiej bez danej zmiennej. Zgodnie z powyższym rysunkiem, w analizowanym przypadku wszystkie czynniki wpływają na ocenę końcową. Największy wpływ mają charakterystyki: stan plomby, stan techniczny pojazdów, czystość środka transportu, czas rozpoczęcia usługi, współczynnik napełnienia cysterny.

W celu podniesienia jakości świadczonych UT w pierwszej kolejności należałoby skupić się na wybranych charakterystykach.

5. PODSUMOWANIE

Uzyskane wyniki wskazują na możliwość wykorzystania sztucznych sieci neuronowych do dokonywania oceny usług transportowych. Zarówno liczba, jak i rodzaj danych (ilościowe lub jakościowe) nie wpływają na osiągnięcie wysokich wyników (95%-99% skuteczności). Na podstawie zgromadzonych danych z przeszłości, sieć neuronowa umożliwia podejmowanie decyzji, generowanie oceny z bieżącej lub przyszłej eksploatacji.

W praktyce istnieją już inne zastosowania sztucznej inteligencji w logistyce. Dla przykładu:

- do oceny zapewnienia jakości środków transportu [8];
- do oceny ryzyka [7];
- do optymalizacji tras przejazdu [10];
- do oceny systemów logistycznych [3].

Przedstawiony w artykule przykład obliczeniowy oddaje istotę zastosowania sztucznej inteligencji do oceny zagadnień związanych z logistyką. Jest to jeden z możliwych punktów wyjścia do prowadzenia dalszych badań nad wykorzystaniem algorytmów sztucznej inteligencji w branży TSL (transport, spedycja logistyka).

Bibliografia

1. Grzelak M.: Planowanie zdolności produkcyjnych w przedsiębiorstwach wytwórczych, Systemy Logistyczne Wojsk nr 45, Warszawa, 2016
2. Jacyna M. (red.): Kształtowanie systemów w wybranych obszarach transportu i logistyki, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2014
3. Kijek M., Brzeziński M, Zelkowski J.: Ocena systemów logistycznych z wykorzystaniem logiki rozmytej, Gospodarka Materiałowa i Logistyka, nr 10, Warszawa, 2016
4. Nałęcz M. (red.): Sieci neuronowe, Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2000
5. Rutkowski L.: Metody i techniki sztucznej inteligencji, PWN, Warszawa, 2005
6. Świderski A.: Modelowanie oceny jakości usług transportowych, Politechnika Warszawska, Warszawa, 2011
7. Świderski A.: Neural modelling of process risk estimation in quality management, Polish Journal of Commodity Science nr 4 (17), Radom 2008
8. Świderski A.: Studies and quality assurance neural modelling of the technical transport means, Archive of Transport, Polish Academy of Sciences Committee of Transport, Volume 21, issue 3-4, Warsaw 2009
9. Pyza D., Jachimowski R.: Modelling of parcels' transport system, w: 19th International Conference Transport Means 2015. Proceedings / Kersys Robertas (red.), TRANSPORT MEANS, 2015, Kaunas University of Technology
10. Werner K., Mierzwiak R., Pochmara J.: Zastosowanie sztucznej inteligencji w logistyce miejskiej, Logistyka, nr 2/2008

ARTIFICIAL INTELLIGENCE ALGORITHMS IN LOGISTICS

Abstract: The article presents artificial intelligence algorithms in logistics. As an example, the neuronal modeling of the rating of transport services have been described. Evaluation method neural networks using multilayer perceptron extract backpropagation algorithm has been proffered. The basis for the verification of the method was experimental research carried out in the production company in food industry. Results of 95-99% probability confirmed the usefulness of neural networks to rating transport services. Other areas of application of artificial intelligence in logistics were also referred to.

Key words: artificial intelligence, neural networks, rating transport services