

**Dariusz SKORUPKA\***  
**Artur DUCHACZEK\***  
**Zbigniew KAMYK\*\***

## **ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH DO OKREŚLENIA KLASY OBCIĄŻENIA POJAZDU**

*W artykule podjęto próbę wykorzystania sztucznych sieci neuronowych (SSN) do identyfikacji klasy obciążenia pojazdów gąsienicowych i kołowych, zgodnie z normą STANAG 2021, na podstawie charakterystycznych wielkości opisujących gabaryty i masę pojazdu. Do rozwiązania problemu użyto sieci liniowej i perceptron wielowarstwowy (MLP). Wyniki odwzorowania klasy MLC przy użyciu SSN nie zapewniają porównywalnej dokładności z metodami analitycznymi. Zaproponowana SSN nie była w stanie prawidłowo analizować klasy MLC pojazdów, których charakterystyki geometryczne nie były zbliżone do pojazdów hipotetycznych przedstawionych w STANAG 2021.*

**Słowa kluczowe:** most, nośność mostu, Military Load Classification (MLC), sztuczne sieci neuronowe, pojazd

### **1. ISTOTA PROBLEMU**

Cywilna inżynieria mostowa bazuje na sprawdzonych algorytmach obliczeniowych, i trudno jest znaleźć pełne uzasadnienie do zastosowania sztucznych sieci neuronowych (SSN). W inżynierii wojskowej jest więcej problemów, które można rozwiązywać za pomocą tzw. miękkich metod analizy, w tym SSN i logiki rozmytej [1]. Pierwsze próby zastosowania SSN w budowie mostów wojskowych przedstawiają m.in. prace [2, 3].

Wojskowa klasyfikacja obciążenia MLC (Military Load Classification) jest standardem NATO, w którym obiekt mostowy ma przydzielony numer klasyfikacyjny

---


\* płk dr hab. inż. Dariusz SKORUPKA, mjr dr inż. Artur DUCHACZEK – Wydział Zarządzania Wyższej Szkoły Oficerskiej Wojsk Lądowych

\*\* dr inż. Zbigniew KAMYK – Wojskowy Instytut Techniki Inżynierskiej

wyrażający obciążenie, jakie może przenieść dla przejazdu pojazdów w jednej lub w dwóch kolumnach. STANAG 2021 [4] przewiduje 16 klas obciążenia zarówno gaśienicowego, jak i kołowego. Podstawowa zasada jednolitej metodologii klasyfikowania obiektów mostowych i pojazdów nakazuje porównać rzeczywisty pojazd z pojazdem hipotetycznym poprzez porównanie momentów zginających i sił tnących, jakie wywołuje on w konstrukcji przęsła, a następnie określić jego klasę. Jeżeli numer klasy pojazdu jest mniejszy lub równy numerowi klasy mostu, to pojazd może przejechać przez most.

Każdy dowódca i kierowca pojazdu musi mieć świadomość ewentualnych skutków przejazdu kolumn transportowych przez most. Tak, więc należy znać klasę każdego pojazdu (wojskowego i cywilnego) lub umieć ją szybko określić. Typowa procedura do określania klasy pojazdu niestandardowego nadaje się do dokładnych obliczeń algorytmicznych, ale jest stosunkowo pracochłonna. Aby ją skutecznie wykonać trzeba mieć doświadczenie w zakresie obliczeń statycznych budowli, czego nie posiadają dowódcy pododdziałów transportowych.

Celem autorów artykułu jest odpowiedź na pytanie czy wykorzystując SSN możliwa jest ocena klasy MLC pojazdów wojskowych bez potrzeby określania sił wewnętrznych wywołanych przez nie w przęsle, a oparta jedynie na analizie porównawczej charakterystycznych wielkości geometrycznych i obciążeniowych podanych w [4], takich jak masa pojazdu, obciążenie poszczególnych osi i odległości między nimi lub długość przylegania gaśienicy (rys. 1). W celu skrócenia i uproszczenia klasycznej procedury klasyfikacji pojazdów autorzy zdecydowali się opracować sieć neuronową, która pozwoli w bardzo szybki sposób określić klasę pojazdu, bez konieczności posiadania wiedzy z zakresu budownictwa mostowego.



Rys. 1. Charakterystyka geometryczno-masowa pojazdu gaśienicowego i kołowego klasy 40 MLC

Źródło: [4]

## 2. METODYKA POSZUKIWANIA ROZWIĄZANIA

W przypadku pojazdów gaśienicowych wektor uczący składał się z czterech argumentów:

$$W = \{M, S, B, MLC\};$$

Pierwsze trzy to dane wejściowe niezależne:  $M$  - masa pojazdu,  $S$  - długość przylegania gaśienicy i  $B$  - szerokość pojazdu. Czwartą wielkością była klasa  $MLC$  pojazdu gaśienicowego jako wielkość zależna (wyjściowa). Natomiast w przypadku pojazdów kołowych wektor uczący składał się aż z 12 argumentów:

$$W = \{M, P_1, P_2, P_3, P_4, P_5, L_1, L_2, L_3, L_4, B, MLC\};$$

Pierwsze jedenaście to dane wejściowe niezależne, takie jak  $M$  - masa pojazdu,  $P_i$  - obciążenie przypadające na kolejną oś pojazdu,  $L_i$  - odległości między osiami tego pojazdu oraz jego szerokość -  $B$ . Dwunastą wielkością była natomiast klasa  $MLC$  pojazdu kołowego jako wielkość zależna.

Badania prowadzono trzyetapowo, w pierwszym i drugim etapie dobór struktury sieci realizowany był poprzez opcję „*automatycznego projektanta*”. W trzecim etapie analizy prowadzone były „*na piechotę*” po uwzględnieniu wyników uzyskanych przede wszystkim w II etapie. W analizowanym zadaniu w pierwszych dwóch etapach badań korzystano z opcji próbkowania bootstrapowego dostępnej w programie *STATISTICA Sieci Neuronowe*, w którym podzbiór uczący otrzymywany jest przez losowanie ze zwracaniem, tzn. że jeden przypadek może zostać wylosowany więcej razy, a jest to bardzo ważne przy małej liczbie danych [5].

*Automatyczny projektant sieci* jest narzędziem, w poważny sposób wspomagającym tworzenie i testowanie sieci neuronowych używanych w analizie danych i zagadnień predykcyjnych. Posiada on opcję umożliwiającą tworzenie zespołu sieci, który daje wspólny wynik przez głosowanie lub uśrednianie. *Zespoły* zwykle lepiej generalizują wiedzę niż pojedyncze sieci. Kolejną ciekawą opcją *Automatycznego projektanta sieci* jest możliwość odrzucenia neuronów lub wejść o małych wagach, co powoduje znaczne zmniejszenie zarówno jakości, jak i błędów analizowanej sieci [5].

W analizach uwzględniono sieci liniowe (Liniowa), perceptron wielowarstwowy (MLP - *Multilayer Perceptron*), samoorganizującą się mapę cech, tzw. sieć Kohonena (SOFM - *Self-Organizing Feature Map*), sieć o radialnych funkcjach bazowych (RBF - *Radial Basis Function*), probabilistyczną sieć neuronową (PNN - *Probabilistic Neural Networks*) i sieć realizująca regresję uogólnioną (GRNN - *General Regression Neural Networks*).

### 3. WYNIKI BADAŃ I ICH ANALIZA

W I etapie badań analizowano wyniki, które zostały przedstawione w tabeli 1, dla pięciu wybranych sieci o najmniejszym błędzie walidacyjnym oraz dla zespołu sieci (lp. 6). Analizując wyniki przeprowadzonych obliczeń stwierdzono, że w przypadku sieci określającej klasę pojazdu gąsienicowego *Automatyczny projektant* wybierał sieci liniowe i MLP. Wybierając dla sieci liniowej jako metodę uczenia metodę pseudoinwersji PI (najmniejszych kwadratów), a dla sieci MLP metodę wstecznej propagacji błędów (Back Propagation) i metodę gradientów sprzężonych (Conjugate Gradient).

Tabela 1. Wyniki obliczeń w I etapie badań

Lp.	Pojazd gąsienicowy				Pojazd kołowy			
	Typ sieci	Błąd			Typ sieci	Błąd		
		uczenia	walid.	test		uczenia	walid.	test
1.	MLP 1:1-12-1:1	0,000560	0,000112	0,000299	MLP 8:8-29-8-1:1	0,009222	0,000745	0,007541
2.	Liniowa 2:2-1:1	0,000023	0,000079	0,000100	MLP 10:10-12-1:1	0,023810	0,000697	0,037019
3.	Liniowa 3:3-1:1	0,000020	0,000048	0,000076	MLP 9:9-26-8-1:1	0,007513	0,000575	0,013351
4.	MLP 1:1-13-1:1	0,000133	0,000041	0,000127	MLP 9:9-30-10-1:1	0,025646	0,000488	0,027128
5.	Liniowa 1:1-1:1	0,000019	0,000031	0,000035	MLP 7:7-30-12-1:1	0,007767	0,000464	0,018518
6.	Wyj. 3:[5]:1	0,000151	0,000062	0,000127	Wyj. 11:[5]:1	0,014792	0,000594	0,020712

Źródło: Opracowanie własne

W przypadku sieci określającej klasę pojazdu kołowego najlepsze wyniki uzyskano tylko dla sieci MLP (tabela 1), przy czym w tym przypadku brano pod uwagę przede wszystkim sieci z dwoma warstwami ukrytymi. Wybierając dla nich również metodę wstecznej propagacji błędów i metodę gradientów sprzężonych. Ze względu na fakt, iż w tym przypadku na wejściu było aż jedenaście neuronów wielkość błędów była znacznie większa niż w przypadku sieci analizującej pojazdy gąsienicowe (tylko trzy neurony w warstwie wejściowej).

W obu przypadkach stwierdzono, że *Automatyczny projektant* proponował odrzucenie neuronów wejściowych o małych wagach lub małej wrażliwości. W przypadku sieci analizującej klasę MLC pojazdów gąsienicowych w trzech przypadkach na pięć, zdecydował się na sieć tylko o jednym neuronie wejściowym (tj. masa pojazdu). Podobna sytuacja zaistniała również w przypadku sieci opisującej klasę MLC pojazdów kołowych, gdzie na jedenaście neuronów wejściowych *Automatyczny projektant* proponował ich od siedmiu (lp. 5) do dziesięciu (lp. 2).

Po przeanalizowaniu obliczeń z I etapu (tabela 1), do drugiego etapu badań zdecydowano się przyjąć sieci MLP, o liczbie neuronów w warstwie wejściowej odpowiadającej liczbie zmiennych niezależnych, tzn. nie zdecydowano się na odrzucenie neuronów wejściowych o małych wagach. W przypadku sieci analizującej klasę MLC pojazdów gąsienicowych przyjęto tylko jedną warstwę ukrytą, natomiast w drugim przypadku (tzn. pojazdu kołowego) zarówno jedną, jak i dwie warstwy, ponieważ ten przypadek był znacznie bardziej złożony. Liczba neuronów w warstwach ukrytych dobierana była „ręcznie” poprzez obserwację błęd dla zbioru walidacyjnego (jako jedna z możliwych opcji programu *STATISTICA Sieci Neuronowe*). Wyniki uzyskane w II etapie badań przedstawiono w tabeli 2.

Tabela 2. Wyniki obliczeń z II etapu badań

Lp.	Pojazd gąsienicowy				Pojazd kołowy			
	Typ sieci	Błąd			Typ sieci	Błąd		
		uczenia	walid.	test		uczenia	walid.	test
1.	MLP 3:3-23-1:1	0,003146	0,003639	0,002977	MLP 11:11-8-1:1	0,034413	0,027065	0,026090
2.	MLP 3:3-12-1:1	0,008040	0,003378	0,002915	MLP 11:11-30-6-1:1	0,057329	0,014717	0,026432
3.	MLP 3:3-19-1:1	0,004375	0,003137	0,002102	MLP 11:11-18-1:1	0,016245	0,007211	0,049772
4.	MLP 3:3-18-1:1	0,008289	0,002883	0,003251	MLP 11:11-30-3-1:1	0,009206	0,006016	0,075663
5.	MLP 3:3-22-1:1	0,004372	0,001259	0,003156	MLP 11:11-30-8-1:1	0,17386	0,002355	0,020994

*Źródło: Opracowanie własne*

Po analizie danych w tabeli 2 przystąpiono do kolejnego etapu badań. W przypadku klasy MLC pojazdu gąsienicowego, zdecydowano się przyjąć sieć MLP o strukturze 3:3-20-1:1 (rys. 2a), dla której w wyniku przeprowadzenia kilkunastu prób uzyskano zadowalające wartości błędów. W tabeli 3 (lp. 1) przedstawiono wyniki dla przykładowego procesu nauki.


Przyjęta w procesie modelowania struktura sieci (architektura, funkcja aktywacji neuronów ukrytych oraz algorytm uczenia) charakteryzuje się najniższą wartością błędu RMS (*Root Square Error*). Na rysunku 3a zaprezentowano przebieg zmian wartości błędu RMS podczas uczenia i walidacji sieci MLP, w kolejnych epokach uczenia algorytmem wstecznej propagacji błędów. Wartość błędu RMS wraz z postępem uczenia maleje, a wyraźnie obserwowana zbieżność wartości błędów dla zbioru walidacji i uczenia świadczy o prawidłowym przebiegu procesu uczenia. Ostateczna weryfikacja

modelu w oparciu o zbiór danych testujących wykazała nieznacznie większą wartość błędu RMS niż dla zbiorów uczącego i walidacji, co świadczy o zadowalającym stopniu zdolności sieci do poprawnej predykcji modelowanych związków [6].

Tabela 3. Wyniki obliczeń dla pojazdu gąsienicowego (lp.1) i kołowego (lp.2)

Lp.	Typ sieci	Jakość			Błąd		
		uczenia	walid.	test	uczenia	walid.	test
1.	MLP 3:3-20-1:1	0,006233	0,002670	0,011519	0,001785	0,001815	0,003015
2.	MLP 11:11-30-6-1:1	0,016597	0,051269	0,170769	0,001997	0,003745	0,004483


Źródło: Opracowanie własne



Rys. 2. Struktura sieci przyjęta w przypadku określania klasy MLC pojazdu: a) gąsienicowego, b) kołowego

Źródło: Opracowanie własne


Po analizie danych zawartych w tabeli 2 zdecydowano, aby do III etapu badań, w przypadku klasy MLC pojazdów kołowych, przyjąć sieć MLP o strukturze 11:11-30-6-1:1 (rys. 2.b). Sieć o tak zdefiniowanej strukturze (podobnie ja we wcześniejszym przypadku) uczono algorytmem wstecznej propagacji błędu BP (*Back Propagation*) stosując logistyczną funkcję aktywacji neuronów (rys. 3b). Mimo kilkudziesięciu prób doboru współczynników wykorzystywanych przy uczeniu tego typu sieci, nie uzyskano zadowalających wyników. W tym przypadku błąd walidacyjny przewyższał błąd uczenia, co mogło świadczyć, że wraz z ilością epok sieć zamiast generalizować dane zaczyna uczyć się ich na pamięć. Dla tego przypadku wielkości uzyskanych błędów (tabela 3 lp. 2) była większa niż w przypadku klasy MLC pojazdów gąsienicowych (tabela 3 lp. 1).



Rys. 3. Przebieg zmian wartości błędu RMS podczas uczenia i walidacji sieci MLP w kolejnych epokach uczenia algorytmem wstecznej propagacji błędu, dla pojazdu: a) gąsienicowego, b) kołowego

Źródło: Opracowanie własne

Na rysunku 4 przedstawiono powierzchnie odpowiedzi nauczonej sieci neuronowej MLP. Zaprezentowane charakterystyki przedstawiono w funkcji masy pojazdu  $Zmn1$  oraz szerokości przylegania gąsienicy  $Zmn2$  (rys. 4a), masy pojazdu  $Zmn1$  oraz szerokości pojazdu  $Zmn3$  (rys. 4b) a także długości przylegania gąsienicy  $Zmn2$  oraz szerokości pojazdu  $Zmn3$  (rys. 4c). Przedstawione na rys. 4 wyniki symulacji numerycznej potwierdzają nieliniowy charakter wartości klasy MLC pojazdów gąsienicowych zarówno w funkcji masy pojazdu  $Zmn1$ , długości przylegania gąsienicy  $Zmn2$  jak również szerokości pojazdu  $Zmn3$  [6].




Rys. 4. Predykcja wartości klasy MLC dla pojazdu gąsienicowego na podstawie modelu w postaci sieci neuronowej MLP 3:3-20-1: 1, w funkcji: a) masy pojazdu  $Zmn1$  oraz szerokości przylegania gąsienicy  $Zmn2$ , b) masy pojazdu  $Zmn1$  oraz szerokości pojazdu  $Zmn3$ , c) długości przylegania gąsienicy  $Zmn2$  oraz szerokości pojazdu  $Zmn3$ .

*Źródło: Opracowanie własne*

Na rysunku 5 przedstawiono wybrane przykłady predykcji wartości klasy MLC dla pojazdu kołowego na podstawie modelu w postaci sieci neuronowej MLP 11:11-30-6-1:1, w funkcji wartości obciążenia pierwszej  $Zmn2$  i drugiej  $Zmn3$  osi pojazdu (rys. 5a), pierwszej  $Zmn2$  i trzeciej  $Zmn4$  osi pojazdu (rys. 5b) oraz pierwszej  $Zmn2$  i czwartej  $Zmn5$  osi pojazdu (rys. 5c).

W tabeli 4 przedstawiono wyniki obliczeń parametrów regresji zmiennej wyjściowej modelu bazującego na sieci MLP uczonej algorytmem BP. Zaprezentowane charakterystyki regresyjne wyznaczono dla wszystkich zbiorów jednocześnie (uczącego, walidacyjnego i testującego).

Na podstawie danych wartości zmiennej, jaką była klasa MLC, określono charakterystyki regresyjne, z których najważniejszą jest iloraz odchyłeń standardowych [6]. Iloraz ten stanowi główny wskaźnik jakości zbudowanego modelu, gdyż wskazuje na stopień dokładności predykcji. Małe wartości ilorazu odchyłeń standardowych dla błędów mogą świadczyć o zadowalającej realizacji regresji przez sieć [6].



Rys. 5. Predykcja wartości klasy MLC dla pojazdu kołowego na podstawie modelu w postaci sieci neuronowej MLP 11:11-30-6-1: 1, w funkcji wartości obciążenia: a) pierwszej ( $Zmn2$ ) i drugiej ( $Zmn3$ ) osi pojazdu, b) pierwszej ( $Zmn2$ ) i trzeciej ( $Zmn4$ ) osi pojazdu oraz c) pierwszej ( $Zmn2$ ) i czwartej ( $Zmn5$ ) osi pojazdu.

*Źródło: Opracowanie własne*

Tabela 4. Parametry regresji zmiennej wyjściowej modelu bazującego na sieci MLP uczonej algorytmem BP

Lp.	Wyszczególnienie	Sieć MLP o strukturze		Lp.	Wyszczególnienie	Sieć MLP o strukturze	
		3:3-20-1:1	11:11-30-6-1:1			3:3-20-1:1	11:11-30-6-1:1
1.	Średnia	54,62500	54,62500	5	Średni błąd bezwzględny	0,22156	0,55397
2.	Odchylenie standardowe	42,2890	42,28900	6	Iloraz odchyleń	0,00646	0,02196
3.	Średni błąd	0,06869	-0,03416	7	Korelacja	0,99998	0,99976
4.	Odchylenie błędu	0,27332	0,92865				

*Źródło: Opracowanie własne*

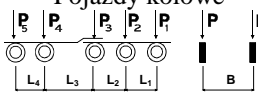
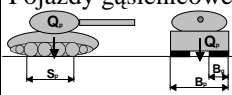
W celu odpowiedzi na pytanie o możliwość wykorzystania SSN do oceny klasy MLC pojazdów wojskowych poprzez analizę charakterystycznych wielkości geometryczno-masowych analizowanych pojazdów porównano wyniki predykcji sieci z metodami analitycznymi.

W tabeli 5 przedstawiono porównanie wyników obliczeń klasy MLC pojazdów uzyskanych przy użyciu prezentowanej SSN oraz przy pomocy tradycyjnego programu opartego na algorytmie wyznaczania wartości sił wewnętrznych zgodnie z [4], a przedstawionego przez autorów w pracy [7]. Do analiz przyjęto przede wszystkim pojazdy rzeczywiste, których charakterystyki geometryczne odbiegały znacznie od wzorców zaprezentowanych w pracy [4], gdyż tylko takie analizy naprawdę weryfikowały działanie stworzonej SSN.

W pierwszej kolejności analizowano pojazdy kołowe. W normie STANAG 2021 [4] nie ujęto pojazdów kołowych o dwóch osiach obciążenia (jak np. DAF, Jelcz 317 i czy amfibia M3) mimo, że w rzeczywistości takich pojazdów jest stosunkowo dużo. Zastosowana SSN w tym przypadku całkowicie nie radziła sobie z realizacją zadania. Aby przy użyciu zaprojektowanej SSN uzyskać zadowalające wyniki należałoby tylną oś tych pojazdów rozbijać fikcyjnie na dwie osie obciążone symetrycznie. W przypadku pojazdów kołowych o masie ok. 8 ton (Star), wynik był dość zadowalający, ponieważ charakterystyka pojazdu zbliżona była do pojazdu normowego klasy MLC8 (tzn. trzy osie równomiernie obciążone). W przypadku Jelcza 662 również SSN nie rozwiązała zadania w sposób zadowalający, co spowodowane było bardzo dużymi wartościami obciążenia przypadającego na poszczególne osie pojazdu oraz odległościami między tymi osiami, zgodnymi z charakterystyką wyższych klas MLC.

Stosunkowo dobre wyniki uzyskano natomiast w przypadku pojazdów gąsienicowych, ponieważ w tym przypadku jedynie podwozie PTS-M nie zostało prawidłowo rozpoznane przez SSN, gdyż jest podwoziem specyficznym, ze względu na bardzo dużą długość pojazdu w stosunku do jego masy. W pozostałych przypadkach wyniki uzyskane tradycyjną metodą były tylko nieznacznie większe, ale prezentowały podobny rząd wielkości. Spowodowane było to faktem, że charakterystyki geometryczne większości rzeczywistych pojazdów gąsienicowych są zbliżone do wzorców klas MLC opisanych w STANAG 2021.

Tabela 5. Zestawienie wyników obliczeń klasy MLC pojazdów uzyskanych przy użyciu sieci neuronowych (SSN) oraz aplikacji komputerowej napisanej w programie Delphi (DEL) a opisanej w pracy [7]

Oznaczenie	Pojazdy kołowe						Pojazdy gaśnicowe			Klasa MLC według		
										DEL [7]		SSN
	$P_1$	$P_2$	$P_3$	$L_1$	$L_2$	$B$	$Q_p$	$S_p$	$B_p$	DEL [7]	SSN	
	[kN]			[m]			[kN]	[m]				
Star	30	30	30	2,97	1,25	2,50	-	-	-	11	9	
DAF	43	60	-	3,95	-	2,45	-	-	-	11	-37	
Jelcz 317	60	90	-	4,10	-	2,60	-	-	-	18	-45	
Jelcz 662	69	79	79	3,82	1,40	2,55	-	-	-	22	55	
M3	121	126	-	6,50	-	2,46	-	-	-	26	143	
TRI	-	-	-	-	-	-	127	3,70	2,85	13	12	
M 113	-	-	-	-	-	-	121	2,67	2,54	13	13	
PTS-M	-	-	-	-	-	-	227	5,10	3,28	25	8	
PT-91M	-	-	-	-	-	-	495	4,27	3,37	54	54	
M1A2Abrams	-	-	-	-	-	-	613	4,65	3,48	70	69	

Źródło: [7]

Analiza wyników zaprezentowanych w tabeli 5, wykazała także, że błędem popełnionym w dotychczas przeprowadzonych analizach było również nieuwzględnienie współczynników wagowych dla wartości danych podawanych na neurony wejściowe. Oczywistym jest fakt, że na wartość otrzymanej klasy MLC pojazdu największe znaczenie ma jego masa, a najmniejsze jego szerokość. Wydaje się, że pewnego rodzaju wartościowanie znaczenia poszczególnych neuronów można dokonać poprzez umiejętne skalowanie danych podawanych na neurony wejściowe, co aktualnie jest tematem kolejnych badań autorów artykułu.

Niewątpliwy wpływ na niezadowalające wyniki obliczeń miała również wielkość zbioru uczącego. W przypadku analizy klasy MLC pojazdów kołowych warunek ten nie był spełniony i pomimo zastosowania w dwóch pierwszych etapach badań próbkowania bootstrapowego, wyniki analiz nie były wystarczająco zadowalające.

## PODSUMOWANIE

Biorąc pod uwagę wielkości błędów generowanych przez sieć, w porównaniu z wynikami klasycznych algorytmów obliczeniowych, należy stwierdzić, że zastosowanie sztucznych sieci neuronowych do oceny klasy MLC pojazdów wojskowych nie jest w pełni celowe. Główne przyczyny to:

- wyniki odwzorowania klasy MLC przy użyciu SSN nie są tak dokładne jak się spodziewano przed przystąpieniem do badań, szczególnie w przypadku pojazdów kołowych (tablica 5),
- opracowana SSN nie była w stanie prawidłowo analizować klasy MLC pojazdów, których charakterystyki geometryczne nie były zbliżone do pojazdów hipotetycznych zawartych w STANAG 2021 [4],



- czas niezbędny do przeprowadzenia niniejszych analiz był niemalże porównywalny z czasem potrzebnym do stworzenia aplikacji komputerowej opartej na algorytmach zaprezentowanych w STANAG 2021 [4].

Powyższe czynniki, zdaniem autorów, znacznie ograniczają możliwości stosowania w tym przypadku SSN. Mimo zaprezentowanych uwag, należy przyznać, że niewątpliwą zaletą przedstawionej SSN jest możliwość bardzo szybkiego otrzymania wyników dotyczących określania klasy MLC pojazdów nawet przez laika, bez konieczności znania skomplikowanych algorytmów stosowanych w procedurze STANAG 2021, która jest przeznaczona głównie dla specjalistów od mostów.

Podsumowując obecne badania autorów i wcześniejsze doświadczenia [7], należy jednak stwierdzić, że zdecydowanie lepsze efekty w określaniu klasy MLC pojazdów można uzyskać stosując standardowe oprogramowanie (np. Borland Delphi, Lazarus, itp.) oparte na klasycznych algorytmach obliczeniowych.

## LITERATURA

- [1] Szelka J., Wrona Z., *Tworzenie wiedzy eksperckiej w zakresie budowy mostów*, [w:] XLVIII Konferencja Naukowa KILiW PAN i KN PziTB „Krynica 2002”, T. 3, s. 357-364.
- [2] Bryda P., Kędra Z., *Zastosowanie sieci neuronowych w analizie nośności konstrukcji przęsłowej mostu składanego DMS-65*, [w:] XI Konferencja Naukowo-Techniczna „Inżynieria i zarządzanie w sytuacjach kryzysowych”, T. 2. Warszawa –Rynia 2000.
- [3] Jarzyna J.R., *Sztuczne sieci neuronowe jako narzędzie oceny czasu montażu mostu tymczasowego*, [w:] XI Konferencja Naukowo-Techniczna „Inżynieria i zarządzanie w sytuacjach kryzysowych” T. 2. Warszawa –Rynia 2000.
- [4] *STANAG 2021 (Ed 6) – Military load classification of bridges, ferries, rafts and vehicles*, 7 September 2006, (NSA/0725-JAS/2021)
- [5] *Instrukcja obsługi programu STATISTICA Sieci Neuronowe* (plik w pomocy programu).
- [6] Józwik J., *Wykorzystanie sztucznej sieci neuronowej do modelowania ugięć sprężystych przedmiotów obrabianych w procesie skrawania toczeniem*, [w:] „Postępy nauki i techniki” nr 4/2010. s. 65-74. [online] [dostęp: 3.03.2011]. Dostępny w Internecie: <http://www.pnt.pollub.pl/pdf/nr4/07.pdf> - dostęp - 3.
- [7] Duchaczek A., Kamyk Z., *Określanie klasy pojazdów niestandardowych według STANAG-u 2021*, [w:] IV Międzynarodowa Konferencja Naukowo-Techniczna nt.: „Uzbrojenie i sprzęt inżynierski sił zbrojnych RP z uwzględnieniem interoperacyjności i kompatybilności ze standardami NATO w działalności naukowo-badawczej”, Polanica Zdrój 27-29 kwietnia 1999, s. 279-288.

## **USE OF ARTIFICIAL NEURAL NETWORKS TO DETERMINE CLASS OF VEHICLE LOAD**

### **Summary**

*The paper is an attempt to use artificial neural networks (ANN) in order to identify military load classification (MLC) of both wheeled and tracked vehicles in accordance with STANAG 2021 on the basis of the specific values of vehicle dimensions and its weight. In order to solve the problem, the authors used linear networks and a multilayer perceptron (MLP). Having analysed the MLC rating results obtained with the ANN, it has been concluded that they do not provide accuracy comparable to the one characterising analytical methods. The ANN proposed was incapable of analysing the MLC properly, in particular the MLC of those vehicles whose geometric characteristics were dissimilar to the hypothetical vehicles included in STANAG 2021 [4].*

**Key words:** *bridge, bridge load-bearing capacity, Military Load Classification (MLC), artificial neural networks, vehicle*

*Artykuł recenzował: płk dr hab. Henryk SPUSTEK, prof. nadzw. WSOWL*