

Mateusz SZARATA¹
Piotr NAZARKO²

ANALIZA MOŻLIWOŚCI ZASTOSOWANIA SZTUCZNYCH SIECI NEURONOWYCH DO KALIBRACJI MODELI MIKROSYMULACYJNYCH

Komputerowe modele ruchu drogowego są powszechnie wykorzystywane do analiz przepustowości i sprawności sieci drogowo-parkingowej. Budowa modeli mikrosymulacyjnych jest procesem długotrwałym i złożonym. Jednym z najbardziej czasochłonnych etapów jest kalibracja modelu. Możliwe jest znaczne przyspieszenie tego procesu poprzez wykorzystanie sztucznych sieci neuronowych do szacowania potencjalnie najkorzystniejszych kombinacji parametrów modelu ruchu. W pracy przedstawiono sposób budowy sieci neuronowych na potrzeby modelowania ruchu na wybranym odcinku drogi oraz zaproponowano procedurę umożliwiającą kalibrację mikrosymulacyjnego modelu ruchu.

Słowa kluczowe: kalibracja modeli mikrosymulacyjnych ruchu drogowego, sztuczne sieci neuronowe, budowa mikrosymulacyjnego modelu ruchu, inżynieria ruchu

1. Wstęp

Modele mikrosymulacyjne ruchu drogowego w ostatnich latach są powszechnie wykorzystywane do przeprowadzania złożonych analiz przepustowości, oceny warunków ruchu oraz logiki sterowania sygnalizacją świetlną. Budowa modeli mikrosymulacyjnych ruchu drogowego jest procesem długotrwałym i złożonym. Wymaga nie tylko przeprowadzenia badań ruchu i odwzorowania sieci drogowej ale również uwzględnienia zachowań kierowców. Proces kalibracji modeli ruchu zakłada przeprowadzenie serii symulacji umożliwiających poprawną kalibrację i uzyskanie modelu bazowego odzwierciedlającego stan bieżący. Jedną z możliwości kalibracji modeli jest metoda eksperymentalna, w której użytkownik ręcznie zmienia parametry modelu. W celu przyspieszenia prac możliwe jest wykorzystanie odpowiednich struktur matematycznych, które umożliwią wygenerowanie

¹ Autor do korespondencji / corresponding author: Mateusz Szarata, Politechnika Rzeszowska, Wydział Budownictwa Inżynierii Środowiska i Architektury, Zakład Dróg i Mostów, matsza@prz.edu.pl


² Piotr Nazarko, Politechnika Rzeszowska, Wydział Budownictwa Inżynierii Środowiska i Architektury, Zakład Mechaniki Konstrukcji, pnazarko@prz.edu.pl

najlepszej kombinacji zmiennych. Jedną z metod umożliwiającą właściwe skonfigurowanie modelu są sztuczne sieci neuronowe (SSN). Są one stosowane do rozwiązywania wielu praktycznych problemów, w których proces otrzymania wyniku na podstawie wprowadzonych danych wejściowych jest skomplikowany i trudny do opisanego i przewidzenia. Przykładem skutecznego zastosowania SSN do kalibracji modeli mikrosymulacyjnych może być publikacja [1]. Autor opracował kompleksowy algorytm umożliwiający kalibrację i jednoczesną walidację modeli ruchu. Największą niedogodnością w tym rozwiązaniu był wymóg przetestowania dużej liczby wzorców (1300 wzorców) w programie mikrosymulacyjnym co przekładało się na długi czas pracy. Ponadto odtworzenie tak skomplikowanego algorytmu nie jest proste, dlatego w przeprowadzonych analizach zaproponowano uproszczoną metodę kalibracji wykorzystującą SSN.

2. Budowa modeli ruchu

Budowa mikrosymulacyjnego modelu ruchu (rys. 1) jest procesem czasochłonnym, wymaga zebrania dużej ilości danych o ruchu pojazdów i sieci drogowej. Pierwszy etap budowy modelu zakłada przeniesienie istniejącego układu drogowego do modelu ruchu. Na podstawie podkładów mapowych odzwierciedla się geometrię ulic i skrzyżowań uwzględniając szerokość i liczbę pasów ruchu, promienie łuków skrotnych oraz pochylenia podłużne niwelety. W kolejnym etapie wprowadzona zostaje organizacja ruchu. Definiujemy warunki przejazdu przez skrzyżowania ustalając zasady pierwszeństwa (w przypadku skrzyżowań bez sygnalizacji świetlnej) lub wprowadzamy programy sygnalizacji świetlnej sterującej ruchem na skrzyżowaniu.

W kolejnym kroku wprowadzamy dane z pomiarów ruchu, które uwzględniają natężenie ruchu, strukturę rodzajową i kierunkową. Na tym etapie wprowadzony zostaje między innymi ruch transportu publicznego. Definiuje się linie



Rys. 1. Etapy budowy mikrosymulacyjnych modeli ruchu (opracowanie własne)

Fig.1. Stages of construction microsimulation traffic models

autobusowe i ich marszrutyżacje oraz czasy związane z wymianą pasażerów na przystanku. Ostatnim etapem prac jest kalibracja i walidacja modelu ruchu, który pozwala odwzorować interakcję poszczególnych pojazdów w sieci drogowej. Program komputerowy Vissim w trakcie przeprowadzenia symulacji wykorzystuje dwa modele zachowań kierowców: model jazdy za liderem Wiedemann 74 (zalecany do odzwierciedlenia ruchu miejskiego) lub Wiedemann 99 (zalecany na arteriach miejskich i drogach szybkiego ruchu) oraz model zmiany pasa ruchu. Są to modele zaliczane do grupy modeli empirycznych. W związku z tym muszą być kalibrowane za pomocą kilkunastu parametrów każdorazowo, uwzględniając lokalną specyfikę ruchu.

3. Założenia do kalibracji mikrosymulacyjnego modelu ruchu

Analizę kalibracji przeprowadzono na modelu opracowanym w 2014 r dla al. Okulickiego w Rzeszowie. Jest to odcinek o długości 1280 m, na którym znajduje się 6 skrzyżowań, w tym 2 z sygnalizacją świetlną, które zlokalizowane są na początku i na końcu odcinka. Aleja posiada przekrój dwujezdniowy, czteropasowy z szerokim pasem dzielącym jezdnie oraz chodniki i ścieżki rowerowe po obu stronach. Proces budowy modelu i zakres badań ruchu został szczegółowo przedstawiony w jednej z wcześniejszych publikacji [2].

W analizowanym przypadku, do kalibracji modelu ruchu przyjęto średni czas przejazdu na odcinku wynoszący 80 s. Zmienne umożliwiające przeprowadzenie procesu kalibracji zostały przedstawione w tabeli 1. Zakres zmiennych

Tabela 1. Parametry uwzględnione w procesie kalibracji

Table 1. Parameters for calibration process

Nr	Parametr	Minimalna wartość	Maksymalna wartość	Zmiana parametru następuje co:
1	<i>Desired Speed Distribution</i> - prędkość w ruchu niezakłóconym; przyporządkowywana jest pojazdowi z odchyleniem 10% [km/h]	50	80	10
2	<i>Number of Observed Preceding Vehicles</i> - Liczba obserwowanych pojazdów znajdująca się przed poruszającym się pojazdem wpływająca na zachowania kierowcy tego pojazdu [P]	1	4	1
3	<i>Average Standstill Distance</i> - średnia odległość pomiędzy pojazdami stojącymi w kolejce lub od punktów stałych (linie zatrzymań) [m]	1	3	0,5
4	<i>Waiting Time Before Diffusion</i> - czas oczekiwania po którym następuje usunięcie zablokowanego modelu z symulacji [s]	15	60	15
5	<i>Minimum Headway</i> - minimalna odległość przed pojazdem umożliwiającą zmianę pasa ruchu [m]	0,5	6,5	1
6	<i>Safety distance reduction factor</i> - współczynnik redukujący odległość bezpieczeństwa [-]	0,05	0,65	0,1

został wyznaczony na podstawie przeglądu literaturowego [3-6]. Dla przyjętej liczby i zakresu zmiennych należałoby przeanalizować łącznie 15680 kombinacji danych wejściowych. Jednak znalezienie odpowiedniego zestawu parametrów dla zakładanego czasu przejazdu nie jest zadaniem łatwym i dlatego do przyspieszenia tego procesu zaproponowano w niniejszej pracy zastosowanie SSN. Wszystkie symulacje zostały wykonane przy pomocy programów Vissim i Matlab.

Program Vissim umożliwia budowę modeli mikrosymulacyjnych ruchu drogowego. Posiada on także możliwość komunikacji z innymi programami komputerowymi poprzez port COM [7]. Dzięki temu możliwa jest wymiana informacji pomiędzy różnymi programami. W tym celu opracowano skrypt programu Matlab, umożliwiający automatyczne uruchamianie i testowanie modeli ruchu z różnymi ustawieniami. Sama tylko automatyzacja tego procesu znacznie przyspiesza i usprawnia pracę.

4. Budowa sztucznej sieci neuronowej

4.1. Koncepcja wykorzystania SSN

Koncepcja wykorzystania SSN do kalibracji modeli mikrosymulacyjnych polega na zastąpieniu czasochłonnych symulacji w dedykowanych do tego celu programach uprzednio wytrenowaną do tego celu siecią neuronową. Trenowanie SSN wymaga jednak utworzenia początkowej bazy wzorców, które zostaną wykorzystane do uczenia się sieci. Wykorzystując następnie zdolności SSN do generalizacji, możliwe jest bardzo szybkie oszacowanie średnich czasów przejazdu. Dzięki temu możliwe jest szybkie znalezienie zestawu parametrów wejściowych, które odpowiadają zakładanym czasom przejazdu. Walidacja tych parametrów w programie Vissim pokazuje dobrą ich zgodność.

4.2. Wzorce do trenowania SSN

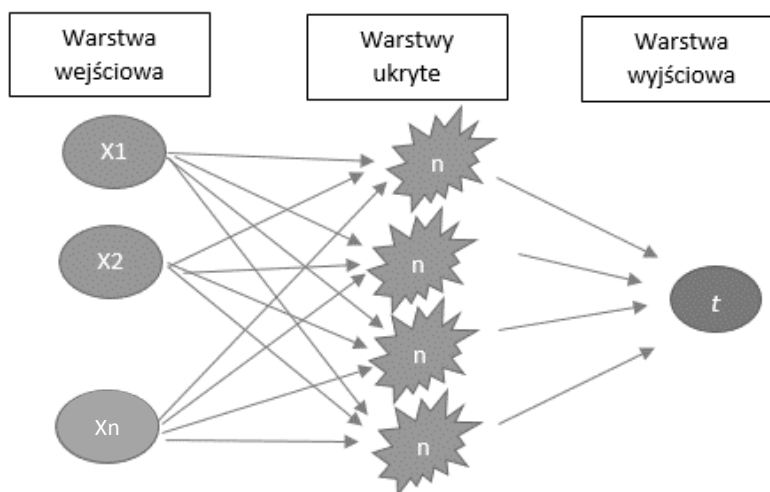
Na potrzeby symulacji wygenerowano w programie Vissim grupę A zawierającą 100 wzorców oraz grupę B zawierającą 50 wzorców. Każdy wzorzec został opracowany zgodnie z założeniami przedstawionymi w tabeli 1 i składał się z sześciu niepowtarzalnych kombinacji parametrów wejściowych. W celu wygenerowania poszczególnych grup wzorców wykorzystano metodę statystyczną Latin Hypercube Sampling (LHS) [8]. LHS pozwala dokonać próbkowania wykorzystując informacje o rozkładzie prawdopodobieństwa danych, przez co wylosowana próbka staje się bardziej reprezentatywna. Wygenerowane w ten sposób zestawy parametrów wejściowych zostały wprowadzone do modelu ruchu al. Okulickiego. Każdy wzorzec podlegał 10 krotnej symulacji uwzględniającej zmianę liczb losowych w symulacji (ang. random seeds). Zmiana parametru 'random seeds', umożliwia między innymi losową generację zgłoszeń pojazdów w przekroju w każdej kolejnej symulacji. Dzięki temu możliwe jest uwzględnienie

nie losowego ruchu pojazdów na analizowanym odcinku. W każdej z symulacji przewidziano 15 min czas początkowy, potrzebny do napełnienia modelu pojazdami i odwzorowaniu warunków ruchu najbliższych do tych, które występowały na początku wyznaczonej godziny szczytu. Po tym okresie rozpoczynał się właściwy pomiar czasu przejazdu. Ostatecznie czasy uzyskane z każdej z 10 symulacji zostały uśrednione dla danego przypadku.

4.3. Trenowanie SSN

Sztuczne sieci neuronowe (rys. 2) w uproszczeniu składają się z następujących warstw:

- warstwy wejściowej, do której podawane są parametry wejściowe (zmienne) modelu,
- warstwy ukrytej, w której znajdują się neurony wytrenowane do rozwiązywania postawionego problemu,
- warstwy wyjściowej, która zwiera oszacowaną odpowiedź układu.



Rys. 2. Uproszczony schemat SSN

Fig. 2. Simplified diagram of SSN

Podczas projektowania architektury SSN należy wyznaczyć liczbę neuronów w warstwie ukrytej, potrzebną do właściwego odwzorowania danych wejściowych w zbiór danych wyjściowych. Proces ten został przeprowadzony doświadczalnie. Należy przy tym pamiętać o problemie nadmiernego dopasowania się sieci do danych uczących [9]. Dlatego też liczba parametrów SSN powinna być mniejsza lub równa liczbie wzorców uczących. Przyjęto zatem szacunkowo, na podstawie maksymalnej liczby parametrów SSN:

$$N = n * (x + y) \quad \text{oraz} \quad N \leq W \quad (1)$$


gdzie: N - liczba parametrów SSN,
 x - liczba zmiennych w wektorze wejściowym,
 y - liczba wyjść sieci,
 n - liczba neuronów w warstwie ukrytej,
 W - liczba wzorców użytych do uczenia SSN,

że maksymalna liczba neuronów w warstwie ukrytej w grupie A wynosi 14 neuronów, a w grupie B 7 neuronów.

Trenowanie sieci neuronowej wymaga również zdefiniowania jaka część wzorców uczących zostanie użyta do procesu testowania SSN. W przeprowadzonych analizach liczby wzorców do testowania zmieniała się od 10% do 30%. Przyjęta do symulacji sieć neuronowa posiadała w warstwie ukrytej nieliniową sigmoidalną funkcję aktywacji, a w warstwie wyjściowej funkcję liniową. Dobraną ostatecznie architekturę SSN, odpowiednio dla wzorców z grupy A i B, można zapisać jako 6-10-1 oraz 6-6-1 (liczba wejść – liczba neuronów w warstwie ukrytej – liczba wyjść).

4.4. Kalibracja modelu ruchu przy użyciu SSN

Po ustaleniu architektury SSN przeprowadzono proces jej trenowania. Ponieważ wynik trenowania zależy od początkowo wylosowanych wartości wag, dlatego proces ten powtarzano wielokrotnie, analizując jednocześnie wyniki pod względem najmniejszych średnich błędów uczenia i testowania. Następnie do wytrenowanej sieci podano pozostałe kombinacje parametrów wejściowych (które nie brały udziału w procesie trenowania), aby oszacować dla nich czasy przejazdu. Przykładowy wynik w postaci histogramu uzyskanych wartości przedstawiono na rys. 3.




Rys. 3. Histogram średnich czasów podróży wygenerowany przez sieć neuronową (grupa A)

Fig. 3. Histogram of average travel times generated by the neural network (grupa A)

Na tej podstawie odszukać można te zestawy parametrów wejściowych, które są najbliższe zakładanemu czasowi przejazdu. W kolejnym etapie zostaną one poddane walidacji w programie Vissim.

W grupie A wytrenowano sieć składającą się z 10 neuronów w warstwie ukrytej i 13% udziałem wzorców do testowania i walidacji. Wytrenowana sieć cechowała się 5 s średnim błędem uczenia i testowania oraz wysokim współczynnikiem korelacji $R^2 = 0,98$. Na rysunku 4 można także zauważyć, że wzorce użyte do uczenia zostały równomiernie rozłożone w całym analizowanym przedziale czasu od 50 s do 90 s. Taki rozkład korzystnie wpłynie na dokładność dalszego szacowania czasów przejazdu w tym przedziale.



Rys. 4. Histogram średnich czasów podróży wygenerowany przez sieć neuronową (grupa A)

Fig. 4. Correlation coefficient results for developed networks (group A)

W celu przeprowadzenia walidacji, spośród wszystkich wygenerowanych wzorców (15680) i uzyskanych czasów przejazdu, wyodrębniono te, dla których SSN wygenerowała średni czas przejazdu równy czasowi otrzymanemu podczas pomiarów ruchu. W grupie A liczba wzorców z czasem 80 s ($\pm 1s$) wynosiła 444. Do sprawdzenia sieci wylosowano 5 zestawów parametrów wejściowych i wprowadzono je do programu mikrosymulacyjnego.


Wyniki przedstawia tabela 2.

Tabela 2. Porównanie średnich czasów przejazdu wygenerowanych przez SSN i program Vissim - grupa A
Table 2. A comparison of average travel times generated by the SSN and the program VisSim - group A

Parametr /no	Wylosowana grupa wzorców				
	1	2	3	4	5
Prędkość w ruchu niezakłóconym [km/h]	50	60	70	80	50
Liczba obserwowanych pojazdów [szt.]	4	2	4	4	1
średnia odległość pomiędzy pojazdami stojącymi w kolejce [m]	3	2	2	1,5	3
czas oczekiwania po którym następuje usunięcie zab. poj. [s]	30	45	15	30	45
min. odl. przed poj. umożliwiającą zmianę pasa ruchu[m]	1,5	6,5	5,5	5,5	4,5
współczynnik redukujący odległość bezpieczeństwa [-]	0,25	0,65	0,65	0,65	0,15
Średni czas przejazdu wygenerowany przez SSN [s]	80				
Średni czas przejazdu wygenerowany przez Vissim [s]	86	75	76	78	88
Odchylenie standardowe [s]	20	17	16	17	19
Różnica	8%	6%	5%	2%	10%
Średnia długość kolejek uzyskana podczas pomiarów [m]	100				
Średnia długość kolejek wygenerowana przez Vissim [m]	109	75	74	69	127
Różnica	9%	25%	26%	31%	27%

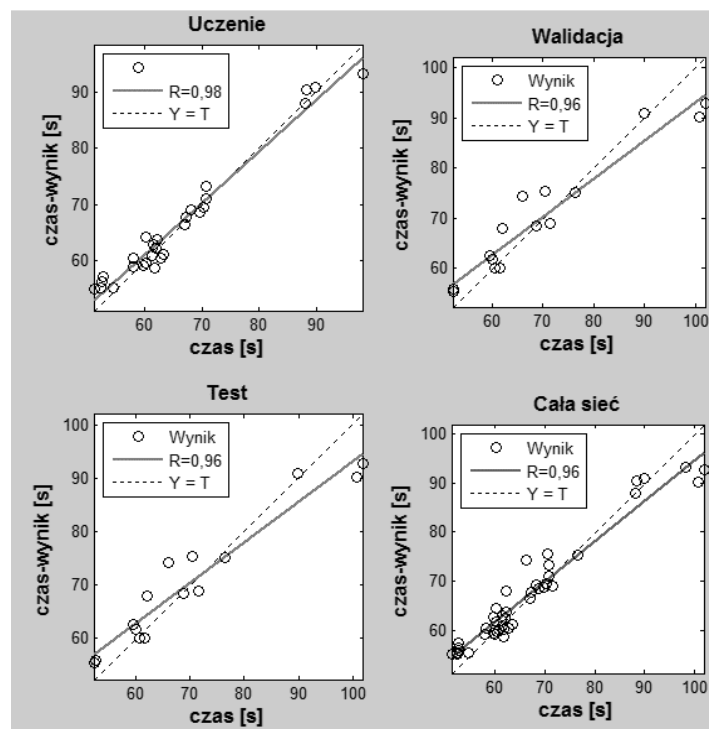
Wszystkie wylosowane wzorce pozwoliły uzyskać zadawalający wynik w modelu ruchu. Różnica średnich czasów przejazdu nie odbiegała więcej niż 10% od wartości pomierzonych w trakcie badań ruchu. Do walidacji modelu wykorzystano średnią długość kolejki, która podczas pomiarów wynosiła 100 m. Z pośród wylosowanych wzorców najlepsze wyniki daje wzorzec 1, gdzie różnica średniego czasu przejazdu wynosi 8% a średnia długość kolejki 9%. Najkorzystniejszy średni czas przejazdu otrzymano z wzorca 4, jednak długość kolejki mocno odbiegała od pomierzonej wartości stąd wykorzystanie tej kombinacji będzie nieuzasadnione.

W grupie B wytrenowano SSN składającą się z 6 neuronów w warstwie ukrytej. Do testowania sieci wykorzystano 28% wzorców. Uzyskana sieć cechowała się średnio 5 s błędem uczenia i średnio 10 s błędem testowania. Na rys. 5 przedstawiono histogram rozkładu wzorców dla poszczególnych czasów, który różni się od poprzedniego (rys. 3). W tym przypadku wygenerowanych zostało znacznie mniej wzorców dla szukanego czasu. Wytrenowana sieć ciągle jednak cechuje się wysokim poziomem korelacji wynoszącym $R^2 = 0,96$.



Rys. 5. Histogram średnich czasów podróży wygenerowany przez sieć neuronową (grupa B)

Fig. 5. Histogram of average travel times generated by the neural network (group B)



Rys. 6. Histogram średnich czasów podróży wygenerowany przez sieć neuronową (grupa B)

Fig. 6. Correlation coefficient results for developed networks (group B)

W przypadku grupy B otrzymany rozkład wzorców uczących w przestrzeni zmiennej wyjścia (rys. 6) nie jest tak równomierny jak poprzednio. Ze względu na ich liczbę, było to trudniejsze do uzyskania algorytmem LHS. Największe zagęszczenie punktów otrzymano w przedziale od 50 s do 75 s. Kolejne punkty uzyskano dopiero powyżej 90 s. Może to bezpośrednio wpływać na dokładność oszacowania czasów przejazdu.

Podobnie jak poprzednio, z całej grupy 15680 wzorców wyodrębniono te, dla których SSN oszacowała średni czas przejazdu równy 80 s. W grupie B liczba wzorców zwracająca czas 80 s (+/- 1s) wynosiła 299. Do sprawdzenia sieci wylosowano 5 i wprowadzono je do programu mikrosymulacyjnego. Wyniki przedstawia tabela 3.

Wylosowane próbki, podobnie jak w poprzedniej grupie, nie różniły się więcej niż o 10% od wartości szukanych czasów. Uwzględniając uzyskane wartości, do dalszych analiz ruchu można wybrany pierwszy wylosowany wzorzec cechujący się 3% różnicą średniego czasu przejazdu i 2% różnicą średniej długości kolejki.

Tabela 3. Porównanie średnich czasów przejazdu wygenerowanych przez SSN i program Vissim -grupa B
Table 3. A comparison of average travel times generated by the SSN and the program VisSim -group B

Parametr \no	Wylosowana grupa wzorców				
	1	2	3	4	5
Prędkość w ruchu niezakłóconym [km/h]	50	60	70	80	50
Liczba obserwowanych pojazdów [szt.]	3	4	2	3	1
średnia odległość pomiędzy pojazdami stojącymi w kolejce [m]	3	2,5	2,5	3	2,5
czas oczekiwania po którym następuje usunięcie zab. poj. [s]	30	60	45	15	30
min.odl.przed poj. umożliwiającą zmianę pasa ruchu[m]	3,5	3,5	4,5	2,5	6,5
współczynnik redukujący odległość bezpieczeństwa [-]	0,15	0,65	0,45	0,45	0,15
Średni czas przejazdu wygenerowany przez SSN [s]	80				
Średni czas przejazdu wygenerowany przez Vissim [s]	82	84	74	78	89
Odchylenie standardowe [s]	24	17	17	18	24
Różnica	3%	5%	7%	2%	10%
Średnia długość kolejek uzyskana podczas pomiarów [m]	100				
Średnia długość kolejek wygenerowana przez Vissim [m]	102	93	82	93	128
Różnica	2%	7%	18%	7%	28%

5. Dyskusja

Wykonane wstępne analizy kalibracji modeli mikrosymulacyjnych przy użyciu SSN, pokazały duży potencjał tej metody. Należy jednak zauważyć, że badania przeprowadzono na prostym modelu ruchu, w którym procesowi kalibracji podlegał tylko jeden średni czas przejazdu. Bardziej rozbudowane modele mogą wymagać przeprowadzenia jednoczesnej kalibracji kilku parametrów np. średniego czasu przejazdu w transporcie publicznym i średniego czasu przejazdu w transporcie indywidualnym. W przypadku uwzględnienia transportu publicznego w modelu zwiększy się zakres zmiennych wchodzących w skład wzorca (z sześciu do siedmiu). Dodatkowa zmienna, której zakres będzie zmieniać się w zakresie 3 wartości, potroi liczbę możliwych kombinacji co w istotny sposób wpłynie na czas potrzebny do analizy danych. Zaproponowane użycie metody Latin Hypercube Sampling, pozwoliło uzyskać na tyle szeroki przedział wyników średnich czasów, aby umożliwić efektywne wytrenowanie SSN. W przypadku prostych modeli, zadawalające efekty można uzyskać przy niewielkiej liczbie próbek. Jak zauważono, wylosowane w grupie A i B wzorce pozwoliły otrzymać równie dobre wyniki. Wygenerowana grupa 50 wzorców pozwoliła uzyskać rozkład wyników w zakresie od 50 do 100 s, przy czym największe zagęszczenie wyników otrzymano w zakresie od 50 s do 70 s. Przyjęcie mniejszej liczby początkowej wzorców mogłoby wpłynąć niekorzystnie na poszukiwaną wartość czasu. Dlatego podczas stosowania tej metody proponuje się wygenerowanie wstępnej liczby wzorców (50 szt.), która może być zwiększana.

6. Podsumowanie

W artykule przedstawiono wstępne wyniki dotyczące kalibracji modeli mikrosymulacyjnych przy wykorzystaniu sztucznych sieci neuronowych. Uproszczona metoda kalibracji zakłada zastosowanie następującej procedury:

1. Wygenerowanie początkowej bazy wzorców przy użyciu LHS,
2. Wytrenowanie SSN,
3. Wygenerowanie wszystkich możliwych kombinacji parametrów zwracających poszukiwaną wartość średniego czasu przejazdu,
4. Wybór ostatecznego zestawu zmiennych na podstawie walidacji.

Przedstawiona metoda kalibracji zakłada użycie Latin Hypercube Sampling w celu wygenerowania początkowej kombinacji wzorców, które zostaną wykorzystane do trenowania SSN. Sztuczna sieć neuronowa zostaje utworzona przez użytkownika metodą eksperymentalną, w której analizowane są najważniejsze parametry sieci tj.: średni błąd uczenia, średni błąd testowania, współczynnik korelacji oraz histogram czasów przejazdu. Jak pokazało przeprowadzone doświadczenie, minimalna liczba początkowa wzorców powinna być dobierana w zależności od stopnia skomplikowania modelu. Sugerowana przez autora początkowa grupa wzorców powinna wynosić co najmniej 50 szt., która w przy-

padku otrzymywania słabych wyników z sieci powinna być zwiększana. Kalibracja modelu została wykonana w oparciu o średnie czasy przejazdu na odcinku al. Okulickiego w Rzeszowie a walidacja otrzymanych wyników związana była ze średnią długością kolejek tworzących się na końcu analizowanego odcinka. Wstępne analizy pokazały, że zaprezentowana metoda może z sukcesem posłużyć do kalibracji prostych modeli mikrosymulacyjnych ruchu drogowego.

Literatura

- [1] I. Otkovic, T. Tollazzi, M. Šraml: Calibration of microsimulation traffic model using neural network approach, *Expert Systems with Applications* 40 (2013) 5965-5974, Elsevier.
- [2] Szarata M., Olszewski P.: Analiza efektywności dynamicznie wydzielanego pasa autobusowego, 60 Konferencja PAN i PZiTb Krynica 2014, materiały pokonferencyjne Zeszyty Naukowe Politechniki Lubelskiej Budownictwo i Architektura vol. 13(4), 2014.
- [3] Podręcznik użytkownika Vissim 5.2. PTV Vision 2009.
- [4] Byungkyu Park, J.D. Schneeberger: Microscopic Simulation Model Calibration and Validation, *Transportation Research Record* 1856, Paper No. 03-2531.
- [5] T. Dybicz: Odwzorowanie fenomenu dwóch przepustowości w mikrosymulacyjnym modelu ruchu w programie Vissim, *Zeszyty Naukowo-Techniczne SITK RP, Oddział w Krakowie* 2014, s 41-55.
- [6] R. Dowling, A. Skabardonis, V. Alexiadis: *Traffic Analysis Toolbox Volume*.
- [7] Instrukcja firmy PTV Vision: Introduction to the COM API, Karlsruhe Germany 2015.
- [8] A. Gramacki, J. Gramacki: Redukcja licznosci zbiorów z wykorzystaniem systemu R, Konferencja PLOUG 2011.
- [9] Waszczyszyn, Z. & Ziemiański, Neural networks in the identification analysis of structural mechanics problems, L. Mroz, Z. & Stavroulakis, G.E. (ed.) *Parameter Identification of Materials and Structures*, Springer – Wien, 2005, 265-340.

ANALYSIS OF THE USE OF ARTIFICIAL NEURAL NETWORKS TO CALIBRATION OF MICROSIMULATION TRAFFIC MODEL

Summary

Computer traffic models are widely used for analysis of the capacity and efficiency of road network. Construction of traffic models is a long and complex process. One of the most time-consuming stages of the calibration model, which aim is to reflect real traffic condition. This process can be greatly accelerated by the use of artificial neural networks to generate potentially best combinations of parameters for the traffic model. The paper presents a method of building neural networks for traffic modeling, and proposes a procedure for the calibration process.

Keywords: Calibration of microsimulation traffic models , artificial neural networks, the construction of microsimulation traffic model, traffic engineering

Przesłano do redakcji: 6.03.2017 r.

Przyjęto do druku: 30.06.2017 r.