

**Teresa Pamuła**

Politechnika Śląska, Wydział Transportu

# PRZESTRZENNO-CZASOWY MODEL PREDYKCJI NATEŻENIA RUCHU Z UŻYCIEM SIECI NEURONOWYCH

Rękopis dostarczono: m-c rok

**Streszczenie:** W artykule przedstawiono przestrzenno-czasowy model predykcji natężenia ruchu i dokonano oceny własności predykcyjnych implementacji tego modelu z użyciem sieci neuronowej MLP (Multilayer Perceptron) oraz sieci typu DLN (Deep Learning Network) bazującej na autoenkoderach. Danymi wejściowymi jest zbiór sekwencji wartości natężeń ruchu z urządzeń pomiarowych umieszczonych w sieci skrzyżowań. Predykcja wykonywana jest jednocześnie dla wszystkich węzłów sieci. Takie podejście uwzględnia zależności przestrzenno-czasowe między danymi z punktów pomiarowych. Walidację modelu wykonano z użyciem danych z piętnastu punktów pomiarowych rozmieszczonych na siedmiu skrzyżowaniach. Wykorzystano 15 minutowe natężenia ruchu drogowego dla dni roboczych zarejestrowane przez detektory z Centrum Sterowania Ruchem w Gliwicach.

**Słowa kluczowe:** predykcja natężenia ruchu, sieci neuronowe, deep learning

## 1. WSTĘP

W ostatnich latach można zaobserwować na świecie, a również w Polsce, szybki postęp w zakresie wdrażania złożonych systemów sterowania i zarządzania w sieciach transportowych. Dla sprawnego funkcjonowania tych systemów, zwanych powszechnie inteligentnymi systemami transportowymi (ITS), kluczowe znaczenie ma zdolność do przewidywania zmian warunków ruchu. Metody przewidywania wykorzystują dane bieżące i historyczne wzorce ruchu dostarczane przez różne systemy monitorowania sieci drogowej. Systemy te różnią się niezawodnością i są w różnym stopniu podatne na zdarzenia drogowe.

Zwiększenie wydajności przewidywania, można uzyskać uwzględniając relacje między punktami monitorowania ruchu w sieci drogowej. Wzajemne rozmieszczenie urządzeń pomiarowych i ich położenie w korytarzach komunikacyjnych stanowią dodatkowe dane wspomagające dla opracowania prognoz ruchu. Innym rozwiązaniem poprawiającym wyniki predykcji może być zwiększenie liczby punktów pomiarowych. To podejście prowadzi jednak do generowania ogromnych ilości danych, które mogą powodować nieprzewidywalne trudności w przetwarzaniu.

Łączenie danych o ruchu, parametrów sieci dróg i stanów detektorów pojazdów jest domeną nieparametrycznych metod przewidywania zmian warunków ruchu, zwłaszcza metod wykorzystujących sztuczną inteligencję.

W literaturze można znaleźć przykłady skutecznego przewidywania zmian parametrów ruchu przy użyciu metod opartych na: liniowych modelach przebiegu ruchu, filtrowaniu, nieparametrycznych reprezentacjach ruchu i na hybrydowych kombinacjach modeli [2], [5]. Metody hybrydowe stanowią wyzwanie związane z przetwarzaniem i są rzadko realizowane w praktyce.

Zmiany parametrów ruchu na jednym skrzyżowaniu wpływają na stan ruchu sąsiednich skrzyżowań. Tą zależność wykorzystano w pracy [1] do optymalizacji działania modelu prognostycznego. Autorzy proponują metodę predykcji opartą na jednokierunkowych sieciach neuronowych o radialnych funkcjach bazowych (RBF).

Podejście uwzględniające czasoprzestrzenne relacje między danymi jest proponowane w [3]. W artykule, do obliczenia estymatora regresji dla predykcji czasu podróży, został wykorzystany wzorzec ruchu dla sąsiednich punktów pomiarowych.

Nieparametryczne modele przebiegu ruchu pozwalają w największym stopniu uwzględnić relacje między czynnikami warunkującymi zmiany przebiegu [8]. Dynamika ruchu może być połączona z charakterystyką sieci i historycznym wzorcem zachowań [6].

W [10] proponuje się wykorzystanie do nauki charakterystyk natężenia ruchu sieci typu Deep Learning (DLN) bazującej na stosie autoenkoderów. Autorzy twierdzą, że model z powodzeniem odwzorowuje złożone zależności między potokami ruchu, takie jak korelacje przestrzenne i czasowe. Badania wykazały również, że w porównaniu do modeli typu MLP lub RBF model DLN daje lepsze wyniki predykcji i jest bardziej wydajny.

Zastosowanie w sieci neuronowej stosu autoenkoderów zbadano również w [4]. Stwierdzono, że taka sieć jest skutecznym narzędziem do prognozowania przepływu ruchu wzdłuż autostrady. Inne prace badawcze zaprezentowane w [8] wskazują, że rozbudowa struktur przyczynia się do mniejszych wartości błędów, ale nie powoduje decydujących zmian w sposobie odwzorowania przebiegu zmian ruchu.

Celem prezentowanej pracy jest opracowanie metody predykcji natężenia ruchu w sieci skrzyżowań. Wyniki predykcji uwzględniać mają zależności czasoprzestrzenne między punktami pomiarowymi – źródłami danych. Użyto sieć neuronową typu Multilayer Perceptron (MLP) oraz sieć tzw. „głęboką” Deep Learning (DLN) bazującą na autoenkoderach dla oceny efektywności odwzorowania przebiegu ruchu w sieci skrzyżowań i jego prognozowania.

Równoległe przewidywanie natężenia ruchu na sąsiadujących węzłach sieci pozwala na uwzględnienie zależności przestrzenno-czasowych co nie występuje w przypadku modeli predykcji dla pojedynczych punktów pomiarowych. Uzyskany w ten sposób przestrzenno-czasowy model predykcji został poddany walidacji.

Opracowany model testowano na danych z sieci składającej się z 7 skrzyżowań, na których mierzono natężenia ruchu drogowego w 15 punktach pomiarowych.

Do trenowania i walidacji wykorzystano dane z rzeczywistych pomiarów w sieci drogowej miasta Gliwice. W badaniach uwzględnione zostały tylko dni robocze od poniedziałku do piątku, ponieważ dla tych dni dobowe przebiegi natężeń zachowują swój charakter [7].

Przygotowano i zweryfikowano kilkanaście modeli sieci neuronowych, z tego wybrano dwa i wyniki tych badań przedstawiono w tym artykule.

## 2. OPIS PROBLEMU BADAWCZEGO

Sterowanie ruchem ulicznym w sieciach dróg przez zintegrowane inteligentne systemy opiera się na wiarygodnej informacji o parametrach ruchu drogowego. Na obszarze miejskim w sieci ulic zmiany parametrów ruchu na jednym skrzyżowaniu wpływają na stan ruchu sąsiednich skrzyżowań. W przypadku predykcji tych parametrów niezależnie dla każdego punktu pomiarowego wzajemne zależności nie są brane pod uwagę. Metoda predykcji z użyciem sieci neuronowej umożliwia przewidywanie parametrów ruchu równocześnie dla grupy punktów pomiarowych.

Na podstawie danych historycznych sieć uczy się zależności, które miały miejsce w przeszłości między punktami pomiarowymi. Parametrem, wybranym do analizy w tym opracowaniu jest natężenie ruchu. Parametr ten jest podstawą do podejmowania decyzji w zakresie sterowania i zarządzania w ITS.

Do przewidywania wartości natężenia ruchu wykorzystywane są sieci neuronowe o różnych strukturach. Wybrano najczęściej stosowaną sieć typu MLP oraz coraz częściej stosowaną do predykcji sieć typu Deep Learning bazującą na autoenkoderach.

Zaproponowano dwa modele predykcji natężenia ruchu z użyciem jednej sieci neuronowej (typu MLP lub DLN) równocześnie w piętnastu punktach pomiarowych rozmieszczonych na dziesięciu skrzyżowaniach w obszarze miejskim. Takie podejście umożliwia równoległe przetwarzanie danych o natężeniu ruchu w sieci skrzyżowań i tym samym uwzględnienie zależności przestrzenno-czasowych między tymi skrzyżowaniami.

Sieć neuronowa na podstawie zbioru treningowego liczącego kilkadziesiąt tysięcy sześćoelementowych sekwencji uczących dla każdego z punktów pomiarowych potrafi rozpoznać podane sekwencje wartości natężenia ruchu w zbiorze testowym i prawidłowo określić wartość przyszłego natężenia ruchu w kolejnym interwale czasowym nawet wtedy, jeśli bieżące wartości natężenia dla danego okresu odbiegały istotnie od danych historycznych. Choć przygotowanie ciągów uczących oraz proces uczenia sieci neuronowej jest czasochłonny, (ale wykonywany off-line) to po jej wytrenowaniu wartość przyszłego natężenia uzyskuje się natychmiast. Pozwala to na wykorzystanie jednej sieci neuronowej (typu MLP lub DLN) do predykcji natężenia ruchu równoległe na wielu punktach pomiarowych w aplikacjach działających w czasie rzeczywistym w inteligentnych systemach transportowych.

Wektor natężeń ruchu dla pojedynczego punktu pomiarowego  $i$ , w chwili  $t$ , gdy uwzględnimy zestaw  $k$  wartości przeszłych natężeń ruchu można wyrazić wzorem:

$$s_i(t) = (q_i(t), q_i(t - \Delta t), \dots, q_i(t - k\Delta t)) \quad (1)$$

gdzie

$\Delta t$  – interwał czasowy dla danych,

$s_i$  – natężenie dla węzła sieci  $i$ ,

$t$  – czas bieżący,

$q_i(t - \Delta t)$  – natężenie ruchu w chwili poprzedzającej czas bieżący  $t$  o wartość interwału  $\Delta t$ .

Wartości predykcji  $\hat{q}_i(t + \Delta t)$  w każdym punkcie  $i$  są wyliczane na podstawie  $N$  zestawów wartości natężenia ruchu  $s_1, s_2, \dots, s_N$  ( $S$ ) zbieranych w punktach pomiarowych


rozmieszczonych w głównych węzłach ruchu sieci drogowej. Zakładając, że na sieci drogowej rozmieszczono  $N$  punktów pomiarowych, przewidywane natężenie w chwili  $t+\Delta t$  można wyrazić wzorem:

$$\hat{q}_i(t + \Delta t) = P(s_1, s_2, \dots, s_N) \quad (2)$$

Wartość natężenia ruchu w chwili  $t+\Delta t$  w danym punkcie pomiarowym na skrzyżowaniu zależy więc od natężeń od chwili  $t-k\Delta t$  do  $t$  w tym punkcie, a także od wartości przeszłych natężeń ruchu w innych punktach pomiarowych w tym samym okresie czasu.

Wstępne badania serii danych natężenia ruchu oraz wcześniejsze badania [7] przy użyciu podobnego zestawu danych pozwoliły na określenie długości obserwacji na 6 okresów pomiarowych od czasu  $t-5\Delta t$  do  $t$  ( $k$  równe 5). Dla 15 min interwałów oznacza to, że przewidywanie opiera się na poprzednich 90 minutach obserwacji ruchu.

Wejścia sieci stanowiły wartości historyczne z każdego z badanych punktów, po 6 wartości poprzednich. Wyjścia sieci stanowiły kolejne wartości natężenia ruchu dla 15 punktów pomiarowych ( $N=15$ ). Sieć neuronowa miała więc 90 wejść i 15 wyjść - rys.1.



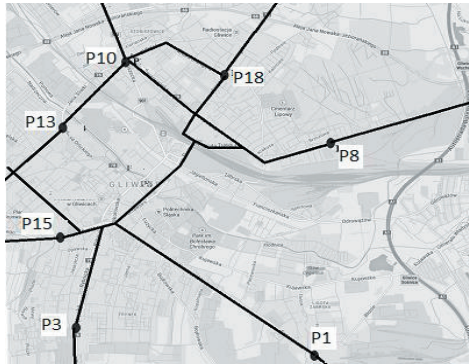
Rys.1. Model predykcji natężenia ruchu dla grupy  $N$  detektorów (źródło: opracowanie własne)

W badaniach wykorzystano dwa rodzaje sieci neuronowych – prostą sieć typu MLP z metodą uczenia typu backpropagation i jedną warstwą ukrytą oraz drugą sieć – coraz częściej ostatnio stosowaną również do predykcji – sieć typu DLN bazującą na autoenkoderach.

### 3. BAZA DANYCH POMIAROWYCH

Zestaw danych do trenowania i testowania sieci pochodzi z bazy danych obsługiwanej przez Centrum Sterowania Ruchem ITS. Do badań wybrano 15 miejsc pomiaru natężenia ruchu ( $N=15$ ) rozmieszczonych na 7 skrzyżowaniach miasta Gliwice, stanowiących punkty wlotowe do miasta oraz wylotowe z centrum. W przypadku tego centrum sterowania pojazdy liczy się w odstępach 5 minutowych. Dane te zostały przeliczone na 15 minutowe wartości natężenia ruchu i takie dane wykorzystano do nauki i testowania sieci neuronowych.

Mapa na rysunku 2 przedstawia położenie siedmiu analizowanych skrzyżowań. Detektory rozmieszczone na skrzyżowaniach w punktach pomiarowych rejestrowały strumienie wideo z kamer zamontowanych nad pasami ruchu.



Rys.2. Rozmieszczenie analizowanych punktów pomiarowych (źródło: opracowanie własne)

Do nauki i testowania sieci wykorzystano ponad 8000 danych pomiarowych dla każdego z 15 detektorów, w sumie ponad 100 tys. danych pomiarowych. Dane te stanowiły 85 dni roboczych od stycznia do maja 2015 roku, w tym dane uczące to 83 dni robocze, dane testowe dwa dni robocze. W badaniach analizowano dane o natężeniu ruchu w interwałach 15 minutowych. Pojedyncze brakujące dane dobowe uzupełniono przez wartość średnią natężenia z poprzedniego i następnego interwału czasowego. W przypadkach, gdy brakowało większej liczby danych, odrzucono dane z całej doby. Nie uwzględniano struktury rodzajowej pojazdów. Wszystkie dane dotyczą liczby pojazdów rzeczywistych.

Średnie dobowe natężenia ruchu w badanych punktach pomiarowych przedstawiono w tablicy 1.

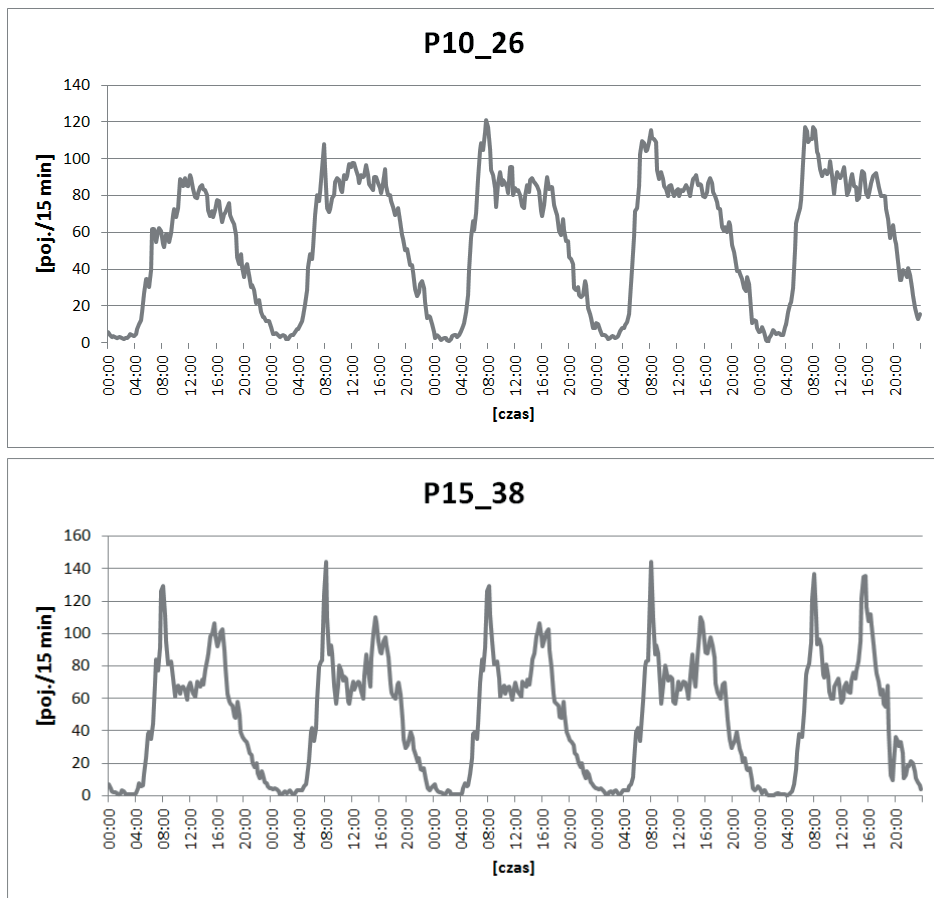
Tablica 1

**Średnie dobowe natężenia ruchu dla danych uczących i testowych**

Punkt pomiarowy	Średnie natężenie [poj./15 min]		Punkt pomiarowy	Średnie natężenie [poj./15 min]	
	ciąg uczący	ciąg testowy		ciąg uczący	ciąg testowy
P1_1	105	105	P13_34	86	90
P1_2	105	112	P10_26	58	55
P3_5	88	106	P10_25	103	112
P3_6	88	84	P18_47	71	63
P15_38	48	55	P18_48	53	59
P15_39	45	51	P8_23	125	153
P13_33	58	58	P8_24	166	154
P13_36	54	55			

Średnie dobowe natężenia mają wpływ na wielkość błędów predykcji, szczególnie błędów bezwzględnych, takich jak na przykład błąd predykcji RMSE (4).

Natężenia ruchu w dniach roboczych dla badanych punktów pomiarowych miały powtarzalny dobowo trend, co jest warunkiem uzyskania dobrych wyników predykcji. Przykładowe tygodniowe przebiegi natężenia ruchu dla dwóch wybranych punktów pomiarowych P10\_26 i P15\_38 na rys. 3.



Rys. 3. Tygodniowe przebiegi natężenia ruchu dla punktów pomiarowych P10\_26 i P15\_38 (źródło: opracowanie własne)


Dane historyczne dobowych natężeń ruchu każdego z badanych detektorów w dniach roboczych wykazują duże podobieństwo, zarówno w godzinach szczytów porannych, popołudniowych, jak i pomiędzy tymi godzinami.

### 3. WYKONANE BADANIA I ANALIZA WYNIKÓW

W modelu z użyciem sieci neuronowej typu MLP zastosowano jednokierunkową sieć dwuwarstwową, z jedną warstwą ukrytą i warstwą wyjściową liczącą 15 neuronów. Dla neuronów warstwy ukrytej funkcją przejścia był tangens hiperboliczny, dla neuronów

warstwy wyjściowej funkcja liniowa. Wejścia sieci stanowiły poprzednie wartości natężenia ruchu, po 6 dla każdego skrzyżowania, co daje w sumie 90 wejść. Piętnaście wyjść sieci to prognozowane wartości natężenia ruchu w następnym interwale czasowym dla każdego z piętnastu punktów pomiarowych na 7 skrzyżowaniach. W wyniku badań różnych struktur sieci wybrano sieć o 12 neuronach w warstwie ukrytej.

W modelu z użyciem sieci DLN wykorzystano sieć o strukturze przedstawionej na rys. 4. Sieć składa się z jednego autoenkodera o 50 neuronach ukrytych oraz warstwy backpropagation o 12 neuronach ukrytych. Zadaniem autoenkodera jest wykrycie 50 cech ( $f_1, \dots, f_{50}$ ) ciągu uczącego. Te cechy stanowią wejścia warstwy backpropagation.



Rys.4. Model predykcji natężenia ruchu dla grupy  $N$  detektorów z użyciem sieci deep learning z autoenkoderem (źródło: opracowanie własne)

Optymalna konfiguracja autoenkodera została ustalona w wyniku wielu eksperymentów. Zwiększenie liczby autoenkoderów oraz dodanie większej liczby neuronów w warstwie ukrytej nie wpłynęło znacząco na poprawę wyników predykcji. Przykładowo przy zastosowaniu stosu dwóch autoenkoderów po 20 neuronów w warstwach ukrytych uzyskiwano nieco większe wartości błędów.

Przygotowane modele przetestowano z wykorzystaniem danych nie biorących udziału w uczeniu. Dla każdego z detektorów wyznaczono błędy predykcji. Do testu użyto danych z losowo wybranych dwóch dni roboczych z miesiąca marca, z których dane nie były elementami ciągu uczącego. Obliczono błędy, które najbardziej charakteryzują wyniki predykcji, takie jak:

- średni bezwzględny błąd procentowy MAPE (Mean Absolute Percentage Error),

$$\text{MAPE} = \frac{1}{M} \sum_{i=1}^M \frac{|q_i(t) - \hat{q}_i(t)|}{q_i(t)} \quad (3)$$

- pierwiastek błędu średniokwadratowego RMSE (Root Mean Squared Error)

$$\text{RMSE} = \sqrt{\frac{1}{M} \sum_{i=1}^M (q_i(t) - \hat{q}_i(t))^2} \quad (4)$$

gdzie:

$M$  – całkowita liczba danych testowych,  $q_i(t)$  – wartości zmierzone,  $\hat{q}_i(t)$  – wartości prognozowane odpowiadające wartościom zmierzonym  $q_i(t)$ .

W tabelach z wynikami predykcji zamieszczono średnie wartości błędów z tych dwóch dni. Obliczono błędy MAPE oraz RMSE dla prognoz sieci z użyciem ciągu uczącego liczącego 119520 sekwencji uczących, po 7968 dla każdego z 15 punktów pomiarowych. Dane te obejmowały okres 83 dni roboczych.

Błędy obliczono dla przewidywanego natężenia ruchu w godz. 6.00 – 22.00. Średnie wartości błędów prognozy MAPE oraz RMSE z dwóch testowanych dni dla wszystkich punktów pomiarowych przedstawiono w tabelicy 2.

Tabela 2

**Wartości błędów predykcji RMSE i MAPE dla 15 punktów pomiarowych**

Punkty pomiarowe	Rodzaj sieci NN	RMSE		MAPE	
		MLP 90-16-15 [veh/15 min]	DLN 90-50-16-15 [veh/15 min]	MLP 90-16-15 [%]	DLN 90-50-16-15 [%]
P1_1		18,3	22,1	10,7	12,2
P1_2		20,5	28,0	10,9	14,5
P3_5		14,9	14,6	8,8	8,7
P3_6		11,8	9,6	8,9	7,6
P15_38		17,5	14,6	21,2	18,0
P15_39		6,5	9,2	7,3	10,3
P13_33		7,2	7,8	7,2	8,0
P13_36		10,0	10,0	10,3	10,3
P13_34		13,5	18,0	11,5	12,0
P10_26		6,3	5,0	7,0	5,7
P10_25		15,4	15,4	9,1	9,1
P18_47		11,9	11,9	12,9	12,4
P18_48		11,9	11,9	8,4	9,4
P8_23		20,9	20,9	8,0	8,0
P8_24		16,7	17,9	7,1	7,7
średnia		<b>13,6</b>	<b>14,5</b>	<b>10,0</b>	<b>10,3</b>

Błędy w tabelicy 2 wyświetlono w kolejności podawanych w sieciach wartości historycznych i wartości predykcji oraz w kolejności rozmieszczenia na mapie miasta - w kierunku wskazówek zegara.


Na rys. 5 zilustrowano średnie bezwzględne błędy procentowe MAPE dla każdego z punktów pomiarowych dla obu opracowanych modeli.

Największe błędy predykcji dla obu modeli dla danych testowych wystąpiły dla punktu pomiarowego P15\_38, najmniejsze dla punktu P10\_26. Dla dziesięciu detektorów błąd MAPE nie przekroczył 10%, dla czterech błąd ten był niższy od 15%.

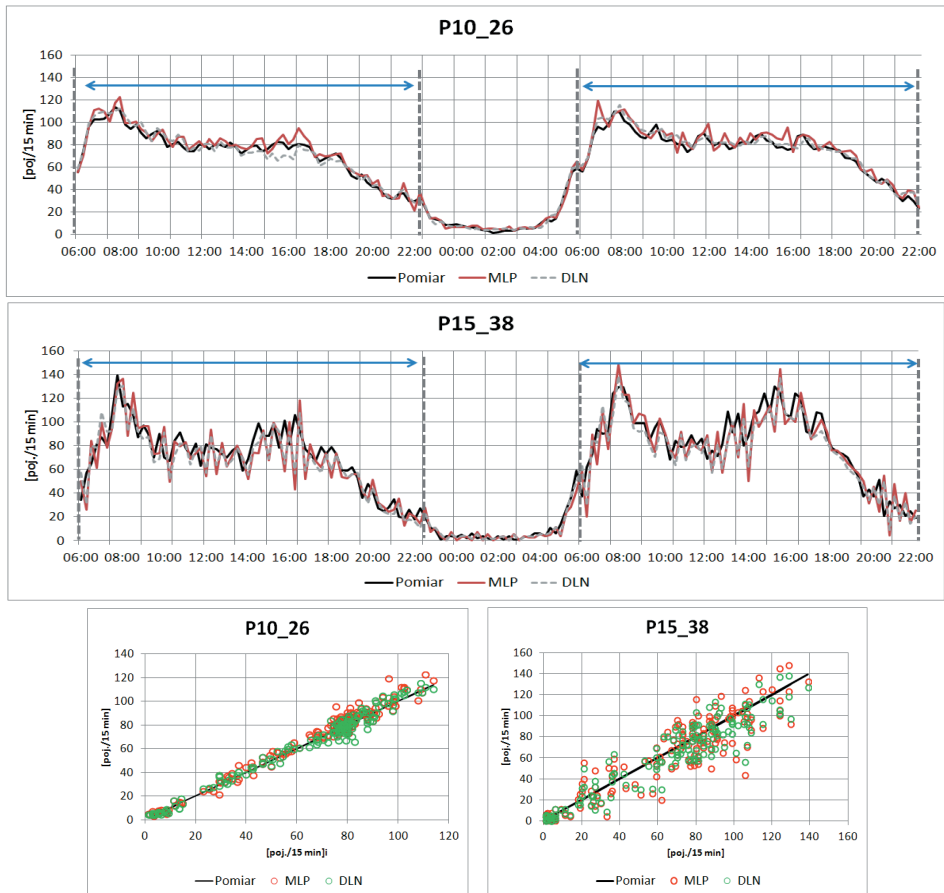
Błąd predykcji MAPE w przypadku, kiedy wszystkie detektory były sprawne wyniósł od 7 do 21,2% dla sieci MLP i od 5,7 do 18% dla sieci DLN. Średni błąd MAPE dla wszystkich detektorów był większy dla sieci DLN o 0,3% co do wartości bezwzględnej.

Na rys. 6 przedstawiono wyniki predykcji natężenia dla dwóch punktów pomiarowych, dla danych testowych, dla których błąd predykcji był najmniejszy (P10\_26) i największy (P15\_38). Błędy predykcji obliczono dla natężeń ruchu w godz. 6.00 – 22.00. Ten obszar wykresu ten zaznaczono między pionowymi liniami przerywanymi.





Rys. 5. Porównanie błędów predykcji dwóch zaproponowanych modeli (źródło: opracowanie własne)



Rys. 6. Dzielne przebiegi natężeń dla dwóch punktów pomiarowych: P10\_26 – najmniejszy błąd MAPE i P15\_38 – największy błąd MAPE dla obu sieci (źródło: opracowanie własne)

Błąd predykcji MAPE jest najmniejszy dla punktu pomiarowego P10\_26 o małych wahanach natężenia między kolejnymi interwałami czasowymi wynoszącymi dla zbioru testowego średnio 4,7 [poj./15 min], a największy dla punktu P15\_38 o stosunkowo dużych różnicach natężen średnio 11,5 [poj./15 min].

Sieć MLP wykazuje większe miejscowe odchylenia wartości predykcji dla obu punktów z rys. 6 niż sieć DLN.

## 5. PODSUMOWANIE

Przygotowano dwa modele do równoległej predykcji natężenia ruchu dla 15 punktów pomiarowych. Wyniki predykcji dla sieci MLP oraz sieci DLN są bardzo podobne. Średnio minimalnie lepsza okazała się sieć MLP. Dla wszystkich sprawnych detektorów średni błąd predykcji dla danych testowych wyniósł 10% dla sieci MLP i 10,3% dla sieci DLN. Za to dla sieci DLN zauważono mniejsze wahania wartości błędu predykcji MAPE dla punktów pomiarowych. Największy błąd predykcji dla sieci DLN wyniósł 18% dla punktu P15\_38, najmniejszy 5,7% dla punktu P10\_26. W przypadku sieci MLP największy błąd wyniósł 21,2% a najmniejszy 7% dla tych samych punktów pomiarowych.

Należy dodać, że sieć neuronowa uczyła się zależności między wartościami natężenia ruchu w analizowanych punktach pomiarowych na podstawie danych historycznych i takie zależności potrafiła następnie odwzorować. Na zależności te mogą mieć wpływ sytuacje wyjątkowe, jak np. kolizje i związane z tym zmiany w strumieniach ruchu rejestrowanych w punktach pomiarowych. Można sądzić, że w ciągu uczącym zawierającym dane z 85 dni roboczych większość zależności związanych z różnymi warunkami drogowymi zostało uwzględnionych. Dlatego też nie ma potrzeby analizy tych zależności przed trenowaniem sieci. To jest podstawowa zaleta zastosowania jednej sieci neuronowej do predykcji natężenia ruchu od zastosowania w tym przypadku 15 niezależnych sieci, dla każdego punktu pomiarowego oddzielnie. Wadą jest konieczność sprawdzenia wrażliwości detektorów w sieci na dokładność predykcji w przypadku uszkodzenia jednego z nich. Takie badania są prowadzone i zostaną opublikowane w innych materiałach.

Na podstawie uzyskanych wyników predykcji natężenia ruchu można stwierdzić, że zaproponowane neuronowe modele predykcji po niewielkiej modyfikacji mogą być zastosowane w inteligentnych systemach wspomagania lub zarządzania ruchem działających w czasie rzeczywistym.

## Bibliografia

1. Asif M.T., Dauwels J., Goh C.Y., Oran A., Fathi E., Xu M., Dhanya M.M., Mitrovic N., Jaillet P.: Spatiotemporal Patterns in Large-Scale Traffic Speed Prediction, IEEE Transactions On Intelligent Transportation Systems, Vol. 15, No. 2, 2014, pp. 794-804.
2. Fusco G., Colombaroni C., Isaenko N.: Comparative analysis of implicit models for real-time short-term traffic predictions, IET Intell. Transp. Syst., Vol. 10, Iss. 4, 2016, pp. 270-278
3. Haworth J., Cheng T.: Non-parametric regression for space-time forecasting under missing data, Computers, Environment and Urban Systems 36, 2012, pp. 538-550.

4. Jia Zheng Zhu, Jin Xin Cao, Yuan Zhu: Traffic volume forecasting based on radial basis function neural network with the consideration of traffic flows at the adjacent intersections, *Transportation Research Part C* 47, 2014, p. 139-154.
5. Karlaftis M.G., Vlahogianni E. I.: Statistical methods versus neural networks in transportation research: Differences, similarities and some insights, *Transportation Research Part C* 19, 2011, pp. 387–399.
6. Pamuła T.: Neural networks in transportation research - recent applications. *Transport Problems*, 2016 vol. 11 iss. 2, s. 27-36
7. Pamuła T.: Classification and prediction of traffic flow based on real data using neural networks, *Archives of Transport*, 2012 vol. 24 no. 4, s. 512-522.
8. Smith B. L., Williams B.M., Oswald R. K.: Comparison of parametric and nonparametric models for traffic flow forecasting, *Transportation Research Part C* 10, 2002, pp. 303–321.
9. Yang H.-F., Dillon T. S., Chen Y-P. P.: Optimized Structure of the Traffic Flow Forecasting Model With a Deep Learning Approach, *IEEE Transactions on Neural Networks and Learning Systems*, early access 2016, DOI: 10.1109/TNNLS.2016.2574840
10. Yisheng Lv, Yanjie Duan, Wenwen Kang, Zhengxi Li, and Fei-Yue Wang, Traffic Flow Prediction With Big Data: A Deep Learning Approach, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 16, No. 2, 2015, pp. 865–873

## SPATIOTEMPORAL ROAD TRAFFIC FLOW PREDICTION MODEL USING NEURAL NETWORKS

**Summary:** The paper presents a spatiotemporal model for predicting road traffic flow values. The prediction capabilities of implementations done using MLP (Multilayer Perceptron) and DLN (Deep Learning Network) with autoencoders, neural networks are evaluated. Input data are the set of sequences of traffic flow values collected at measuring sites in the road network. Prediction is carried out simultaneously for all nodes of the road network. This approach takes into account spatiotemporal relations between data from the measuring sites. Validation of the model is done using data from 15 measuring sites located at seven road junctions. 15 min traffic flow values, registered on working days by the Centre of Traffic Control in Gliwice, are used.

**Keywords:** traffic flow forecast, neural networks, deep learning