

PREDYKCJA NATĘŻENIA RUCHU W CIĄGU SKRZYŻOWAŃ Z WYKORZYSTANIEM SIECI NEURONOWYCH

Streszczenie

W artykule zaproponowano wykorzystanie jednej sieci neuronowej do krótkoterminowej predykcji wartości natężeń ruchu dla wylotów dwóch kolejnych skrzyżowań tej samej ulicy. Predykcja natężenia ruchu na drugim skrzyżowaniu została wykonana na podstawie danych historycznych dla skrzyżowania pierwszego. Pozwala to na określenie przyszłego natężenia ruchu na wylocie tego skrzyżowania w przypadku braku danych rejestrowanych na tym skrzyżowaniu. Dokonano walidacji modelu z użyciem historycznych danych otrzymanych z Centrum Sterowania Ruchem w Gliwicach. Baza danych obejmuje dane o natężeniu ruchu z 6 miesięcznego okresu rejestracji w 2014 roku (luty-lipiec). W badaniach wykorzystano wartości natężenia ruchu rejestrowane w odstępach 15 minutowych.

WSTĘP

Przewidywanie parametrów ruchu, takich jak dobowe natężenie ruchu w różnych interwałach czasowych jest jednym z głównych obszarów badawczych w dziedzinie inteligentnych systemów transportowych (ITS) [3], [10]. Predykcja natężenia ruchu wykorzystywana w systemach sterowania ruchem pozwala zwiększyć płynność ruchu i poprawić jego bezpieczeństwo. Dokładne prognozy tych parametrów są istotną częścią skutecznych działań w zaawansowanych systemach zarządzania ruchem. Szczególne znaczenie może mieć możliwość przewidywania parametrów ruchu w miejscu, w którym z różnych przyczyn ruch nie jest rejestrowany na bieżąco. Taką możliwość daje predykcja, w której wykorzystuje się sieci neuronowe. Przewidywanie krótkoterminowe natężenia ruchu jest szczególnie przydatne do podejmowania decyzji sterujących na skrzyżowaniach. Modelowanie przebiegu natężeń ruchu za pomocą NN jest elementem adaptacyjnych algorytmów sterowania ruchem [2], [4],[5],[9].

W literaturze [1], [7] można najczęściej znaleźć wyniki badań predykcji krótkoterminowej dla skrzyżowań lub punktów dróg, na których wcześniej rejestrowano dane i na podstawie tych danych historycznych przewidywano przyszłe parametry ruchu. W artykule przedstawiono wyniki predykcji polegającej na wykorzystaniu danych historycznych na wylocie jednego skrzyżowania i na tej podstawie predykcji natężenia ruchu na wylocie tego skrzyżowania i równocześnie następnego skrzyżowania. Pozwala to na określenie przyszłego natężenia ruchu na wylocie tego skrzyżowania w przypadku braku danych rejestrowanych na tym skrzyżowaniu. Przygotowano i zweryfikowano kilkanaście modeli sieci neuronowych, z tego wybrano cztery i wyniki tych badań przedstawiono w tym artykule.

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 są nie różnią się tak jak w pozostałych dniach tygodnia [6].

1. ANALIZA I SELEKCJA DANYCH

Baza danych natężenia ruchu została przygotowana z użyciem danych z detektorów pojazdów umieszczonych jednej z dróg dojazdowych do Gliwic. Uzyskane pomiary natężenia ruchu obejmują okres sześciu miesięcy od lutego do lipca 2014 roku i pozwalają

obserwować utrwalone schematy przebiegów zmienności. Dane o natężeniu ruchu rejestrowane były w interwałach 5 minutowych. Ze względu na niewielkie natężenie ruchu w godzinach nocnych, wynoszące kilka pojazdów/5 min, do badań przyjęto okresy 15 minutowe. W przeprowadzonych badaniach uwzględniono dane o natężeniu ruchu tylko z dni roboczych, od poniedziałku do piątku.

Mapa na rysunku 1 przedstawia położenie detektorów. Detektory rejestrowały strumienie wideo z kamer zamontowanych nad pasami ruchu. Wiarygodność danych została potwierdzona przez ręczne liczenie pojazdów przeprowadzane w losowych odstępach czasu w trakcie zbierania pomiarów do bazy danych.



Rys. 1. Lokalizacja detektorów

2. OPIS PROBLEMU BADAWCZEGO

Krótkoterminowa predykcja natężenia ruchu polega zwykle na określeniu natężenia ruchu w kolejnym interwale czasu na podstawie danych z kilku poprzednich interwałów czasowych. Długość interwału zależy od przyjętego modelu, ale zwykle jest to 5, 15, 30 lub 60 min. W tych badaniach przyjęto długość interwału czasowego

wynoszącą 15 min. Natężenie prognozowane jest więc funkcją natężeń w poprzednich interwałach czasowych. Można tę zależność opisać w następujący sposób:

$$q(t+1)=Q(q(t), q(t-1), q(t-2), q(t-3), q(t-4), q(t-5))$$

gdzie $q(t)$ to natężenie ruchu zarejestrowane przez detektor w czasie rzeczywistym t , a pozostałe zmienne to natężenia w 5 kolejnych interwałach poprzedzających czas t .

Do predykcji wykorzystuje się dane historyczne z poprzednich miesięcy, a nawet lat. Tego typu prognozy wykonane za pomocą różnych metod [2] dają dobre wyniki i mogą być wykorzystane w Inteligentnych Systemach Transportowych.

W niniejszym artykule opisano badania, w których zaproponowano dodatkowo predykcję natężenia ruchu na wylocie kolejnego skrzyżowania tej samej ulicy. Pomysł takiej predykcji był konsekwencją analizy ruchu w testowanych miejscach. Przeprowadzono analizę statystyczną zarejestrowanych pomiarów i zaobserwowano charakterystyczne zachowanie zmienności natężeń ruchu w zależności dni pomiarów. Dla obu analizowanych skrzyżowań można zauważyć niewielkie różnice w dobowych przebiegach natężenia ruchu w tym samym dniu roboczym.

Można więc przyjąć następujące zależności:

$$q_{JUN1}(t+1)=Q(q(t), q(t-1), q(t-2), q(t-3), q(t-4), q(t-5))$$

i

$$q_{JUN2}(t+1)=Q(q(t), q(t-1), q(t-2), q(t-3), q(t-4), q(t-5))$$

gdzie $q(t)$ to natężenie ruchu zarejestrowane przez detektor na skrzyżowaniu Jun1, w czasie rzeczywistym t , a pozostałe zmienne to natężenia w 5 kolejnych interwałach poprzedzających czas t zarejestrowane również na skrzyżowaniu Jun1.

Dla takich zależności zaproponowano sieć neuronową o sześciu wejściach – sześciu kolejnych natężeniach ruchu do chwili t i dwóch wyjściach określających prognozowane wartości natężenia ruchu na wylotach skrzyżowań Jun1 i Jun2.

3. MODEL PREDYKCJI Z UŻYCIEM SIECI NEURONOWEJ

Jednym z najważniejszych etapów umożliwiających jak najlepsze nauczenie sieci neuronowej jest przygotowanie ciągów uczących. Struktura sieci zależy głównie od rodzaju danych uczących i ich ilości. Jeśli nie można wyróżnić wspólnej cechy dla zbioru grup ciągów uczącego tak, aby sieć działała jak klasyfikator, to liczba wag w strukturze sieci powinna być taka, aby umożliwiła zapamiętanie wiedzy z danych uczących, zwykle kilkakrotnie mniejsza od liczby danych w zbiorze uczącym. W procesie uczenia powinno nastąpić uogólnienie wiedzy w celu późniejszej weryfikacji w oparciu o przypadki nie uwzględnione w procesie uczenia. Ostateczną strukturę sieci ustala się jednak w wyniku testowania różnych konfiguracji, rozpoczynając od tych zgodnych ze standardowymi zasadami [8].

3.1. Ciąg uczący i testowy

Do ciągu uczącego wybrano dane z 25 dni roboczych, po 1 tygodniu (5 dni roboczych) z każdego z pięciu miesięcy od lutego do czerwca. Dobowe wartości natężenia podawane były w interwałach 15 minutowych. Przygotowano ciąg uczący o długości 2400 wektorów. W ciągu uczącym, w którym każdy wektor uczący składał się z sześciu wejść i dwóch wyjść szczególną uwagę zwrócono na to, aby drugie wyjście sieci odpowiadało tym samym dniom, których dotyczyły dane wejściowe. W przypadku pierwszego wyjścia było to oczywiste.

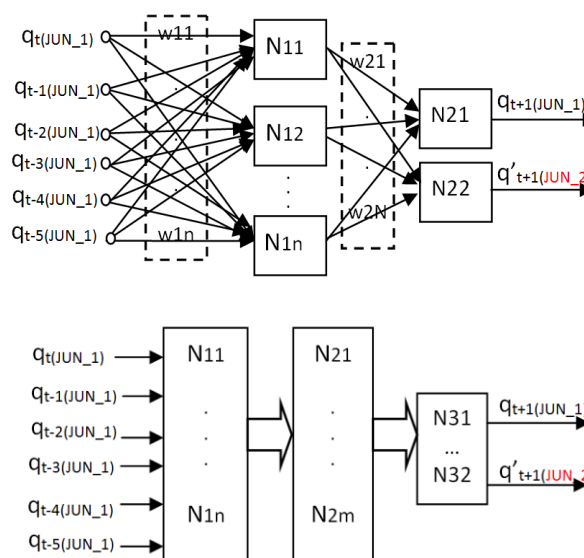
Do testowania sieci wybrano dni z innych tygodni niż te, z których dane o natężeniu wykorzystano w ciągu uczącym. Uzyskane wyniki predykcji za pomocą sieci o różnych strukturach przedstawiono w tabelach w dalszej części tego artykułu.

3.2. Struktura sieci neuronowej

Do rozwiązania problemu predykcji natężenia ruchu na wylocie skrzyżowania Jun1 i wylocie skrzyżowania Jun2 na podstawie danych historycznych zaproponowano jednokierunkową sieć neuronową o 6 wejściach i dwóch wyjściach. Wejścia sieci stanowiły kolejne wartości natężenia ruchu w interwałach 15 min. Wyjścia sieci to prognozowane natężenia ruchu na badanym wylocie skrzyżowania Jun1 i wylocie skrzyżowania Jun2 w kolejnych 15 min.

Zbadano wiele struktur sieci i wybrano dwie sieci dwuwarstwowe o strukturach 6-36-2 i 6-66-2, w których warstwy ukryte liczyły odpowiednio 36 i 66 neuronów, oraz dwie sieci trójwarstwowe o strukturach 6-18-18-2 i 6-36-36-2 z dwoma warstwami ukrytymi o 18 i 36 neuronach w obu warstwach ukrytych.

Dla wszystkich sieci wykorzystano metodę uczenia backpropagation z szybkim algorytmem modyfikacji wag Levenberga-Marquardta. W warstwach ukrytych dla każdego neuronu zastosowano tangensoidalną funkcję przejścia (tanh), a dla dwóch neuronów warstwy wyjściowej liniową funkcję przejścia. Przykładowy schemat zastosowanych sieci neuronowych przedstawiono na rys. 2.



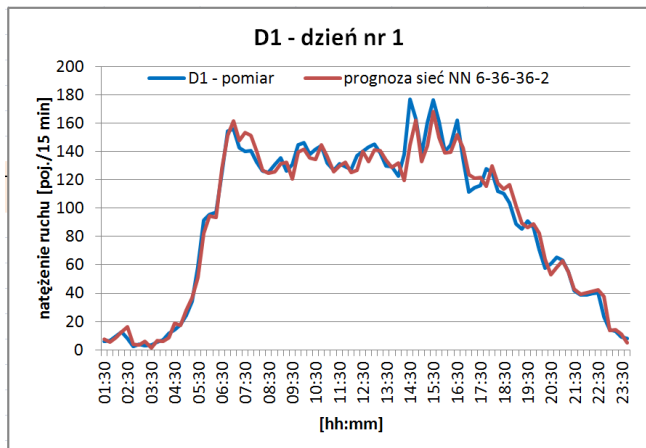
Rys. 2. Struktury zastosowanych sieci neuronowych

Na rysunku 2 przedstawiono schematy dwóch struktur sieci neuronowych zastosowanych w badaniach. Badania wykazały, że uzyskanie dobrych wyników predykcji dla wyjścia 1 (Jun1) wymaga niewielkiej liczby neuronów i jednej warstwy. Już kilkanaście wystarczy do określenia wartości przyszłego natężenia ruchu z dokładnością poniżej 10% [6,10]. Jednak dla uzyskania lepszej dokładności predykcji dla wyjścia 2 trzeba było wykorzystać większą liczbę neuronów w warstwie ukrytej lub dodać jeszcze jedną warstwę ukrytą. Wyniki testów pokazały, że zastosowanie dwóch warstw ukrytych spowodowało uzyskanie dokładniejszej predykcji dla obu wyjść niż w przypadku jednej warstwy ukrytej.


4. WYNIKI TESTÓW

Po wytrenowaniu czterech sieci sprawdzono poprawność ich działania. Zestaw wektorów testowych składał się z danych o natężeniu ruchu z jednej doby i zawierał 96 wartości natężenia ruchu co


dało 90 ciągów, po 6 wartości natężenia ruchu w każdym ciągu od godziny 1:30 do godz 23:45. Dla obu skrzyżowań prognozowana była wartość natężenia ruchu w chwili $t+1$. Dane testowe nie były częścią zestawu użytego do trenowania sieci. Sprawdzone prognozy dla kilku wybranych dni roboczych z różnych miesięcy. Wyniki predykcji dla dnia 16.04.2014 (dzień nr 1) dla detektora D1 przedstawiono na rysunkach 3 i 4, a dla detektora D2 na rysunkach 5 i 6.




Rys. 3. Porównanie wyników prognozowania dla wylotu Skrzyżowania Jun1(det. D1)



Rys. 4. Porównanie wyników prognozowania dla Jun1(det. D1)



Rys. 5. Porównanie wyników prognozowania dla wylotu skrzyżowania Jun2(det. D2)

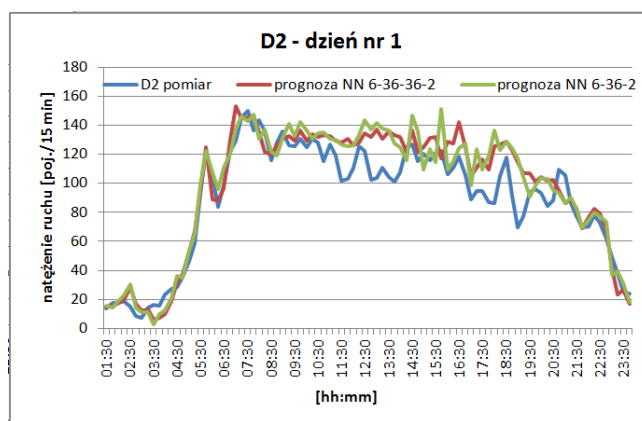


Rys. 6. Porównanie wyników prognozowania dla wylotu skrzyżowania Jun2(det. D2)


Na rysunkach 3, 4, 5 i 6 przedstawiono wyniki prognozowania dla detektorów D1 i D2. Na wykresach 3 i 5 widać przebiegi natężenia ruchu rzeczywistego oraz prognozowanego. Dla detektora D1 uzyskano bardzo dobre wyniki prognozowania – wykresy prawie pokrywają się. Dla detektora D2 z drugiego skrzyżowania prognozy nie są już tak dobre. Na wykresach z rysunków 4 i 6 widać przy jakich natężeniach ruchu występują największe różnice. Rozrzut natężeń dla detektora D1 jest dużo niższy niż dla detektora D2. Idealne dopasowanie (prognoza) ma miejsce wtedy, gdy dane o natężeniu pokrywają się z niebieską linią prostą na wykresach 4 i 6.

Dokładne różnice między wartościami rzeczywistymi (zmierzonymi) a prognozowanymi zostały przedstawione w dalszej części artykułu z wykorzystaniem standardowych wzorów wyrażających błędy między wartościami prognozowanymi, a zmierzonymi.

Na rysunku 7 i 8 przedstawiono wykresy dla danych pomiarowych – wartości rzeczywistych oraz wartości predykcji dla zbioru testowego z dnia roboczego 16.04.2014 roku dla dwóch różnych konfiguracji sieci. Można zauważyć, że przebiegi prognoz obu modeli zachowują charakter zmian przebiegu natężeń ruchu w badanym punkcie. Sieć o strukturze 6-36-36-2 dokładniej prognozuje przyszłe wartości natężenia ruchu niż sieć o strukturze 6-36-2.



Rys. 7. Porównanie wyników predykcji dla różnych struktur sieci



Rys. 8. Porównanie wyników predykcji dla różnych struktur sieci

Dla losowo wybranych trzech dni przeprowadzono analizę błędów predykcji obliczając dla wyznaczonych wartości:

średni błąd predykcji ME (mean error),

$$ME = \frac{1}{N} \sum_{n=1}^N (q_f - q_n)$$

średni błąd bezwzględny (MAE):

$$MAE = \frac{1}{N} \sum_{n=1}^N |q_f - q_n|$$

średni bezwzględny błąd procentowy MAPE (mean absolute percentage error):

$$MAPE = \frac{1}{N} \sum_{n=1}^N \frac{|q_f - q_n|}{q_n}$$

pierwiastek błędu średniokwadratowego RMSE (root mean squared error):

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (q_f - q_n)^2}$$

gdzie:

N – całkowita liczba analizowanych danych, q_n – wartości zmierzone, q_f – wartości prognozowane dla n-tego pomiaru (q_n)

Tabele 1-4 przedstawiają zestawienia wyznaczonych błędów dla detektorów D1 i D2 oraz dla czterech wybranych konfiguracji sieci neuronowych – dwóch sieci dwuwarstwowych i dwóch sieci trójwarstwowych. Znak średniego błędu ME pozwala wnioskować o odchyleniu wartości prognoz. W zależności od wybranego dnia dokładność prognozy może być inna, ponieważ dobowe przebiegi natężeń dla tych dni są różne, a dane te nie były częścią ciągu uczącego.

Tabela 1 zawiera zestawienie błędów dla dnia 16.04.2014 roku. Obliczone błędy są najniższe ze wszystkich testowanych dni. Dokładność prognozy dla detektora D1 na wylocie skrzyżowania Jun1 jest najlepsza dla sieci o strukturze 6-36-36-2. Dla detektora D2 potwierdza się obserwacja z rysunku 5, czyli uzyskiwane prognozy są wyższe od rzeczywistych wartości.

Tabela 2 zawiera zestawienie błędów dla dnia 21.02.2014 roku (dzień nr 2). Można zauważyć na podstawie wartości błędów, że dokładność prognozy dla detektora D1 na wylocie skrzyżowania Jun1 jest najlepsza dla sieci o strukturze 6-36-36-2. Wartości błędów ME dla wszystkich sieci są wyższe niż rzeczywiste. Dla detektora D2 na wylocie skrzyżowania Jun2 najmniejszy błąd predykcji daje sieć o strukturze 6-66-2. Uzyskiwane prognozy są niższe niż wartości rzeczywiste.

Tabela 3 zawiera zestawienie błędów dla dnia 11.03.2014 roku (dzień nr 3). Dokładność prognozy dla detektora D1 na wylocie skrzyżowania Jun1 jest najlepsza dla sieci o strukturze 6-36-36-2. Wartości błędów ME dla wszystkich sieci wahają się od -0,2 do 0,6 i są bardzo bliskie rzeczywistych. Dla detektora D2 na wylocie skrzyżowania Jun2 najmniejszy błąd predykcji daje sieć o strukturze 6-36-2. Uzyskiwane prognozy są niższe niż wartości rzeczywiste, ale dużo dokładniejsze niż dla dnia nr 2.

Tab 1. Tabela wyników prognozy dla detektora D1 i D2 dla dnia nr 1

Błędy	Detektor D1				Detektor D2			
	RMSE [poj/15min]	MAPE	MAE Sredni błąd bezwzgl. [poj/15min]	ME [poj/15min]	RMSE [poj/15min]	MAPE	MAE Sredni błąd bezwzgl. [poj/15min]	ME [poj/15min]
NN 6-36-2	7,4	0,13	5,8	-0,2	23,4	0,19	17,0	-8,2
NN 6-66-2	7,4	0,12	5,8	-0,1	23,8	0,18	17,5	-11,6
NN 6-18x18-2	7,6	0,15	6,1	0,6	23,7	0,19	17,5	-9,3
NN 6-36x36-2	7,2	0,11	5,5	0,5	24,2	0,19	17,7	-8,7

Tab 2. Tabela wyników prognozy dla detektora D1 i D2 dla dnia nr 2

Błędy	Detektor D1				Detektor D2			
	RMSE [poj/15min]	MAPE	MAE Sredni błąd bezwzgl. [poj/15min]	ME [poj/15min]	RMSE [poj/15min]	MAPE	MAE Sredni błąd bezwzgl. [poj/15min]	ME [poj/15min]
NN 6-36-2	9,9	0,23	7,0	0,9	32,4	0,27	25,5	-18,7
NN 6-66-2	9,6	0,15	6,9	0,7	28,7	0,20	20,7	-14,8
NN 6-18x18-2	8,9	0,21	6,8	0,8	35,2	0,30	27,5	-22,2
NN 6-36x36-2	8,9	0,13	6,1	1	29,5	0,23	22,2	-16,4

Tab 3. Tabela wyników prognozy dla detektora D1 i D2 dla dnia nr 3

Błędy	Detektor D1				Detektor D2			
	RMSE [poj/15min]	MAPE	MAE Sredni błąd bezwzgl. [poj/15min]	ME [poj/15min]	RMSE [poj/15min]	MAPE	MAE Sredni błąd bezwzgl. [poj/15min]	ME [poj/15min]
NN 6-36-2	7,4	0,13	5,8	-0,2	23,4	0,19	17,0	-8,2
NN 6-66-2	7,4	0,12	5,8	-0,1	23,8	0,18	17,5	-11,6
NN 6-18x18-2	7,6	0,15	6,1	0,6	23,7	0,19	17,5	-9,3
NN 6-36x36-2	7,2	0,11	5,5	0,5	24,2	0,19	17,7	-8,7

Tab 4. Średnie dla poszczególnych sieci i wszystkich testowanych dni

Błędy	Detektor D1			Detektor D2		
	RMSE [poj/15min]	MAPE	MAE Sredni błąd bezwzgl. [poj/15min]	RMSE [poj/15min]	MAPE	MAE Sredni błąd bezwzgl. [poj/15min]
NN 6-36-2	8,2	0,15	6,0	26,2	0,26	20,1
NN 6-66-2	8,2	0,12	6,1	25,2	0,24	19,1
NN 6-18x18-2	8,0	0,15	6,1	26,3	0,27	20,6
NN 6-36x36-2	7,9	0,12	5,7	24,5	0,24	18,9

Tabela 4 zawiera zestawienie średnich błędów dla wszystkich testowanych dni. Można zauważyć na podstawie wartości błędów, że dokładność prognozy dla wszystkich modeli sieci NN dla obu detektorów jest najlepsza dla sieci o strukturze 6-36-36-2. Dla detektora D1 różnice między uzyskiwanymi błędami są bardzo małe, więc każda z zastosowanych struktur sieci może być wykorzystana do predykcji natężenia. W przypadku detektora D2 sieć o strukturze 6-36-36-2 okazała się wyraźnie lepsza od pozostałych.

Błąd RMSE określa, o ile średnio odchylają się realizacje zmiennej prognozowanej od obliczonych prognoz. Z danych w tabeli 4 wynika, że dla detektora D1 prognozowane wartości natężenia ruchu różnią się od wartości rzeczywistych o około 8 poj./15 min, a dla detektora D2 te różnice wynoszą około 25 poj./15 min.

Błąd MAPE informuje o średniej wielkości błędów prognoz, w tym przypadku dla okresu jednej doby, wyrażonych w procentach rzeczywistych wartości zmiennej prognozowanej. Wartości MAPE pozwalają porównać dokładność prognoz otrzymywanych dla różnych modeli. Średni bezwzględny błąd procentowy MAPE dla detektora D1 oscyluje w granicach 12-15%, dla detektora D2 w granicach 24-27%.

MAE informuje o ile średnio w okresie predykcji rzeczywiste realizacje zmiennej prognozowanej będą się odchyłać co do bezwzględnej wartości od prognoz. Dla detektora D1 wartości błędu MAE są niewielkie i wynoszą około 6 poj./15 min, dla detektora D2 średnie różnice wartości prognozowanych i rzeczywistych są dużo większe i wynoszą od 19 do 21 poj./15 min. Dla detektora D2 w wielu przypadkach wartości prognoz znacząco odbiegały od mierzonych wartości.

WNIOSKI

Uzyskane wyniki dla różnych modeli predykcji z użyciem sieci neuronowej wskazują na możliwość zastosowania sieci neuronowej do przewidywania przyszłego natężenia ruchu dla dwóch skrzyżowań, na podstawie sześciu wartości poprzednich dla pierwszego skrzyżowania.

Dokładność predykcji dla pierwszego skrzyżowania Jun1 jest bardzo dobra dla wszystkich testowanych sieci. Dla skrzyżowania

Jun2 błąd predykcji dla najlepszej sieci wynosi 24% i jest za duży do praktycznych zastosowań. Analiza danych pomiarowych i zachowań modeli wskazują, że aby zmniejszyć błąd prognozy należy uwzględnić dodatkowy parametr, taki jak godzina pomiaru natężenia ruchu.

Można również zastosować dwie niezależne sieci do predykcji natężenia dla każdego z analizowanych skrzyżowań. Takie badania są prowadzone, a wstępne wyniki wskazują na możliwość poprawy predykcji dla skrzyżowania Jun2 nawet o 10%. Można więc stwierdzić, że zaproponowany neuronowy model predykcji po niewielkiej modyfikacji może być zastosowany do wyboru planów sygnalizacji w obrębie skrzyżowań oraz do wspomagania obszarowego zarządzania ruchem.

BIBLIOGRAFIA

- Chen H., Grant-Muller S., Mussone L., Montgomery F.: *A study of hybrid neural network approaches and the effects of missing data on traffic forecasting*, Neural Computing and Applications vol. 10, pp. 277–286, 2001.
- Chrobok, R., Kaumann, O., Wahle, J., Schreckenberger, M.: *Different methods of traffic forecast based on real data*. European Journal of Operational Research 155 (3), pp. 558–568, 2004.
- Guilherme B. Castro, José Sidnei C. Martini, André R. Hirakawa, *Biologically-Inspired Neural Network for Traffic Signal Control*, 2014 IEEE 17th International Conference on Intelligent Transportation Systems (ITSC) October 8-11, 2014. Qingdao, China
- Man-Chun Tan, S. C. Wong, Jian-Min Xu, Zhan-Rong Guan, Peng Zhang: *An Aggregation Approach to Short-Term Traffic Flow Prediction*, IEEE Transactions on Intelligent Transportation Systems, vol. 10, pp. 60-69, 2009.
- Pamula T.: *Traffic flow analysis based on the real data using neural networks*. Telematics in the transport environment. Selected papers. Ed. Jerzy Mikulski. Berlin : Springer, s. 364-371, 2012.

6. Pamula T.: *Classification and prediction of traffic flow based on real data using neural networks*, Archive of Transport, vol. 24 no. 4, s. 519-522, 2012.
7. Srinivasan D., Choy M. C., and Cheu R. L.: *Neural networks for real-time traffic signal control*, IEEE Trans. Intelligent Transportation Systems, vol. 7, no. 3, pp.261-271, Sep. 2006.
8. Tadeusiewicz R. *Sieci neuronowe*. Akademicka Oficyna Wydaw. RM, Warszawa 1993.
9. Vlahogianni E.I., Karlaftis M.G., Golias J.C.: *Optimized and meta-optimized neural networks for short-term traffic flow prediction: a genetic approach*, Transportation Research Part C vol.13, pp.211-234, 2005.
10. Ziwen Leng, Junwei Gao, Yong Qin, Xin Liu, Jing Yin, *Short-term Forecasting Model of Traffic Flow Based on GRNN*, 25th Chinese Control and Decision Conference (CCDC)2013 Nowak J., *Bezpieczeństwo samochodów i ruchu drogowego*. WKiŁ, Warszawa 2004.

THE TRAFFIC FLOW PREDICTION IN THE INTERSECTIONS USING NEURAL NETWORKS

Abstract

The paper presents a proposal of using one neural network for short time prediction of traffic flow on two adjacent junctions of a traffic route. The traffic flow on the second junction is predicted on the basis of historic data registered at the first junction. This allows to forecast the flow on the second junction in the case of failure of its flow measuring devices. The proposed NN is validated using data acquired from the Road Traffic Control Centre in Gliwice. The database consists of traffic flow measurements collected over 6 months in 2014 (February - July). The flow was registered in 15 min intervals.

Autor:

dr inż. **Teresa Pamula** – Politechnika Śląska, Wydział Transportu
email: teresa.pamula@polsl.pl