

Teresa PAMUŁA

PROGNOZOWANIE NATĘŻENIA RUCHU POJAZDÓW NA SKRZYŻOWANIU ZA POMOCĄ SIECI NEURONOWEJ

Streszczenie. Artykuł zawiera wyniki badań prognozowania natężenia ruchu na skrzyżowaniu w Katowicach. Dane wykorzystane do uczenia sieci pochodzą z rzeczywistych pomiarów natężenia ruchu i zostały zarejestrowane przez detektor, umieszczony na wlocie skrzyżowania. Uzyskane wyniki prognozowania zostały porównane z rzeczywistymi danymi i poddane weryfikacji. Badania mają na celu sprawdzenie możliwości i skuteczności wykorzystania sieci neuronowej w inteligentnym systemie zarządzania ruchem miejskim.

PREDICTION OF TRAFFIC VOLUME AT THE JUNCTION USING NEURAL NETWORK

Summary. The article reviews the results of forecasting traffic intensity at the junction in Katowice. Data used for network learning comes from actual measurements of traffic and were recorded by a detector placed at the inlet junction. The results obtained were compared with the prediction of the actual data and verified. The purpose of the study is the feasibility and effectiveness of using neural networks in intelligent urban traffic management system.

1. WPROWADZENIE

Znajomość natężeń ruchu jest niezbędna do określenia tendencji rozkładu ruchu w sieci drogowej oraz prognoz obciążenia tras drogowych i wykorzystania ich przepustowości, zmienności natężeń ruchu w poszczególnych godzinach, dniach i miesiącach, struktur – rodzajowej i kierunkowej oraz obciążenia konstrukcji jezdni. Najczęściej stosowanymi jednostkami czasu są godzina i doba, chociaż w niektórych analizach są stosowane sekundowe natężenia ruchu (intensywności). Pomiary te są prowadzone wyrywkowo, doraźnie lub cyklicznie na drogach miejskich i zamiejskich, a pomiary ręczne, dokładniejsze (np. rozróżnianie typów pojazdów), lecz najbardziej pracochłonne zastępuje się coraz częściej rejestracją automatyczną. Podstawowym interwałem rejestracji natężenia ruchu jest godzina. Do celów specjalnych (np. obliczanie przepustowości) stosuje się interwały: 30-, 15- i 5-minutowe. Czas 15 min jest okresem odniesienia w analizach przepustowości [1].

Istotnym elementem analiz natężeń ruchu są analizy wahań ruchu, związanych z następującymi czynnikami:

- czasem (porą roku, dniem tygodnia, porą dnia, przedziałem czasu w godzinie),
- rodzajem ruchu (miejski, podmiejski, pozamiejski, osobowy i towarowy),
- strukturą rodzajową ruchu,
- typem i przebiegiem drogi,
- stopniem wykorzystania przepustowości.

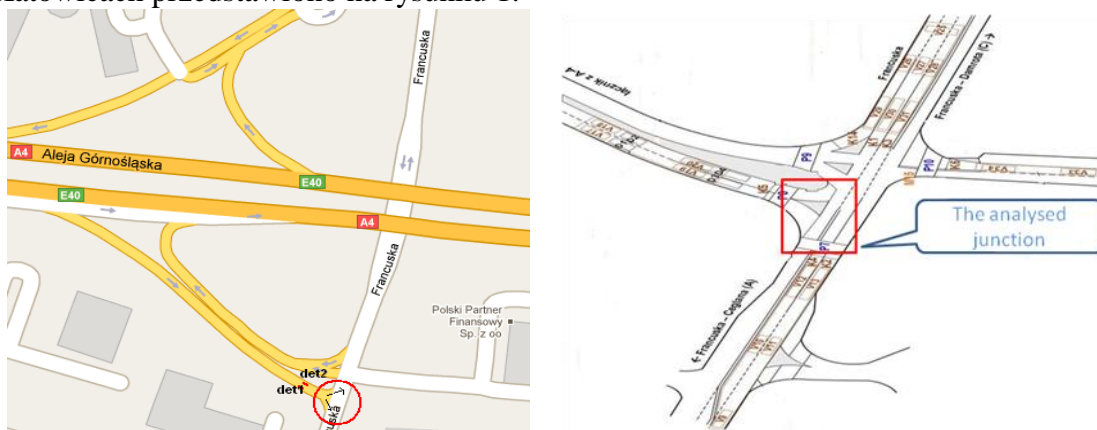
Znaczne wahania ruchu, występujące w poszczególnych dniach tygodnia, zależą także w bardzo dużym stopniu od rodzaju drogi i charakteru ruchu.

W arteriach miejskich i podmiejskich ruch utrzymuje się na ogół na podobnym, wysokim poziomie w dniach roboczych, a w okresie weekendu natężenia ruchu są znacznie mniejsze z wyjątkiem godzin i tras powrotu z weekendu. Drogi zamiejskie charakteryzuje pewne spiętrzenie ruchu w piątki, przed wolnymi od pracy sobotą i niedzielą. Na drogach rekreacyjnych największe natężenie ruchu występuje w soboty i niedziele. Jedną z najważniejszych jest charakterystyka wahań natężenia ruchu w ciągu doby. Natężenie w godzinie szczytu sięga zwykle 8%–12% natężenia całodobowego.

Ruch miejski charakteryzuje się znacznie większymi spiętrzeniami w godzinach szczytu. Szczyt poranny odznacza się zwykle większą ostrością od szczytu popołudniowego, który jest bardziej rozciągnięty w czasie. Na przebieg wahań dobowych wpływa również dzień tygodnia; wyraźne są różnice wahań w dni robocze, soboty i niedziele. Przebieg arterii i jej funkcja mają również wpływ na charakter wahań ruchu. Na kierunkach prowadzących do (od) centrum występują duże spiętrzenia w okresach dojazdów i powrotów z pracy, podczas gdy arterie obwodnicowe są obciążone bardziej równomiernie w godzinach dziennych [1].

Celem badań było sprawdzenie skuteczności trzech niezależnych sieci neuronowych (dla trzech dni tygodnia) zdolnych do prognozowania natężenia ruchu pojazdów na skrzyżowaniu w interwałach godzinnych.

Usytuowanie analizowanego skrzyżowania oraz detektorów przy ulicy Francuskiej w Katowicach przedstawiono na rysunku 1.




Rys. 1. Lokalizacja detektorów przy ul. Francuskiej w Katowicach
Fig. 1. The place of the detectors on the Francuska street in Katowice

Dane wykorzystane w badaniach pochodzą z detektora 2, zainstalowanego na końcu drogi zjazdowej z autostrady w kierunku centrum Katowic. Detektor zapisuje dane o natężeniu ruchu na pasie, z którego pojazdy zjeżdżają do centrum Katowic w odstępach 5-minutowych. Dane zarejestrowane przez detektor 1 nie zostały na razie wykorzystane do badań.

2. ANALIZA DANYCH Z VIDEODETEKTORÓW

Dane o natężeniu ruchu są rejestrowane przez videodetektor w interwałach 5-minutowych. Ze względu na bardzo dużą ich liczbę i to, że do analizy wystarczyły natężenia godzinne, wartości zarejestrowane przeliczono na natężenia godzinne, liczone w odstępach 15-minutowych.


Do badań wybrano 3 dni tygodnia: poniedziałek, wtorek i sobotę. Wykonano analizę porównawczą natężenia ruchu w poniedziałek 25.10.2010r. i 29.11.2010 r. Wyniki porównania przedstawiono na wykresie – rys. 2. Te same badania wykonano dla pozostałych dni tygodnia, czyli wtorku i soboty. Jak łatwo zauważyć przebieg natężenia ruchu w badanym miejscu jest podobny. Największe odchylenia występują w soboty, ponieważ dla większości uczestników ruchu nie jest to dzień pracy, więc natężenie ruchu może nie zmieniać się tak cyklicznie, jak w przypadku dni roboczych. Poza tym sobota 30 października to dzień poprzedzający święto, w związku z tym szczególnie w godzinach rannych mogą mieć miejsce duże różnice w natężeniu ruchu.



Rys. 1. Porównanie natężenia ruchu w poniedziałki

Fig. 2. Comparison of Traffic on Mondays

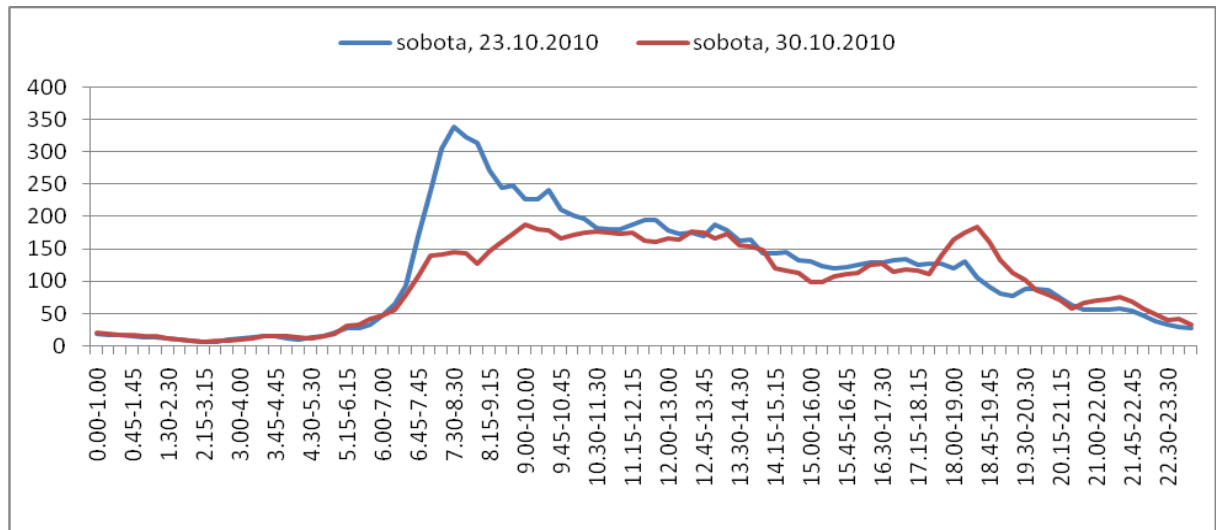
Na rys. 3 przedstawiono wykresy natężenia ruchu we wtorki 26.10.2010 i 30.11.2010. Natężenie ruchu ma bardzo podobny przebieg, co stwarza możliwość prawidłowej predykcji.



Rys. 2. Porównanie natężenia ruchu we wtorki

Fig. 3. Comparison of Traffic on Tuesdays

Na rys. 4 przedstawiono wykresy natężenia ruchu w soboty 23.10.2010r. i 30.10.2010r..



Rys. 3. Porównanie natężenia ruchu w soboty

Fig. 4. Comparison of Traffic on Saturday

W godzinach rannych, tj. od 6.00 do 11.30 wystąpiły duże różnice w natężeniu ruchu pojazdów. Związane to jest z tym, że sobota 30.10.2010r. była dniem poprzedzającym święto, w związku z tym mogła być dniem wolnym od pracy, co spowodowało zmniejszenie liczby pojazdów jadących do centrum w godzinach rannych, a zwiększenie w godzinach popołudniowych. Ze względu na duże wahania natężenia ruchu dane z sobót 23.10.2010r. i 30.10.2010r. nie zostały wykorzystane do uczenia sieci neuronowej. W dalszych badaniach zostaną uwzględnione dodatkowe czynniki mające wpływ na natężenie ruchu, takie jak dzień przedświąteczny, powroty z weekendów czy imprezy masowe, występujące na analizowanym obszarze lub w jego pobliżu.

3. PREDYKCJA NATĘŻENIA RUCHU POJAZDÓW

Prognozowanie polega na przewidywaniu na podstawie zdobytej wiedzy następnych wydarzeń. Jedną z cech sieci neuronowej jest możliwość przewidywania przyszłego rozwoju zjawiska na podstawie obserwacji jego dotychczasowego przebiegu. Jakość prognoz może być różna, w dużej mierze zależy to od stopnia nauczania sieci. Możliwe jest jednak zbudowanie sieci, która nie tylko będzie uwzględniała wiedzę o prognozowanym zjawisku, nabytą w trakcie treningu, ale także pozytywne lub negatywne doświadczenia zdobywane podczas realnego prognozowania. W takim wypadku mamy do czynienia z douczaniem sieci. [6]

Jeżeli dokonujemy pomiarów ruchu, w których każdy pomiar wykonany jest z równym odstępem czasu, to zebrane dane stanowią szereg czasowy. Wykonać możemy analizę danych w takim szeregu i, jeżeli wykazuje ona pewną prawidłowość, dokonać również predykcji kolejnej, niezmierzonej jeszcze w danej chwili, wartości. Predykcja w szeregu czasowym bazuje na wartościach z przeszłości w celu próby oszacowania wartości w kolejnych punktach czasu. Dane z przeszłości, na podstawie których stara się przewidzieć kolejną wartość szeregu, stanowią okno czasowe. Może ono obejmować wszystkie dotychczas zebrane dane lub też możemy ograniczyć je tylko do N ostatnich pomiarów. Decyzja o wyborze szerokości okna danych może być podyktowana wynikami wstępnej analizy występujących w szeregu zależności. Przykładowo, jeżeli wiemy, że wartości w pewnym pomiarze powtarzają się

w sposób cykliczny, to w skład okna czasowego wybrać możemy pomiary z kilku ostatnich cykli.

Predykcja krótkookresowa to taka, w której chcemy przewidzieć tylko jedną kolejną wartość. Kiedy natomiast chcemy dokonać predykcji długookresowej, gdzie liczba przewidywanych przyszłych pomiarów jest większa, to dla każdego kolejnego estymowanego pomiaru okno danych powiększane jest o poprzednio znaną wartość. Jakość danych uzyskanych w procesie predykcji mierzy się zazwyczaj jako średnie odchylenie wartości, uzyskanych w procesie predykcji w stosunku do danych, otrzymanych w rzeczywistym pomiarze.

W związku z tym, że natężenia ruchu pojazdów cechują pewne cykliczne prawidłowości, wydaje się możliwe opracowanie modelu predykcyjnego. Zaproponowany model predykcji wykorzystuje sieć neuronową. Wybór ten podyktowany był faktem, że sieci neuronowe stanowią grupę metod sztucznej inteligencji, które we wstępnym etapie uczenia dość dobrze radzą sobie ze znajdowaniem pewnych ukrytych prawidłowości. Sieci neuronowe posiadają dodatkową pożądaną cechę, którą jest umiejętność uogólniania danych, charakteryzująca się tym, że nawet w przypadku dostarczenia na wejście sieci danych zaszumionych sieć potrafi zwrócić prawidłową odpowiedź, co czyni ją dobrym narzędziem w procesie predykcji danych [8]. Wszystkie sieci utworzono w symulatorze sieci neuronowych Neuronix, który wchodzi w skład pakietu SPHINX firmy Aitech. Każda z sieci prognozuje natężenia dla innego dnia tygodnia.

3.1. Ciągi uczące sieci neuronowej

W ciągu uczącym przyjęto długość okna czasowego równą 5 godzin. W związku z tym, że rozpoczęcie pomiarów natężenia dla kolejnych godzin następuje co 15 minut, okno czasowe liczy 20 wartości. Tabela 1 zawiera godzinne wartości natężeń dla kolejnych, następujących po sobie co 15 minut, dwudziestu godzinnych interwałów czasowych we wtorki. Wartości te to wejścia sieci, które umieszczone zostały w kolumnach oznaczonych jako „we”. Ostatnia, oznaczona jako „wy”, to wartość na wyjściu sieci. Jest to wartość natężenia, która ma być zaprognozowana.

Tabela 1.

Fragment ciągu uczącego dla sieci neuronowej (wtorki)

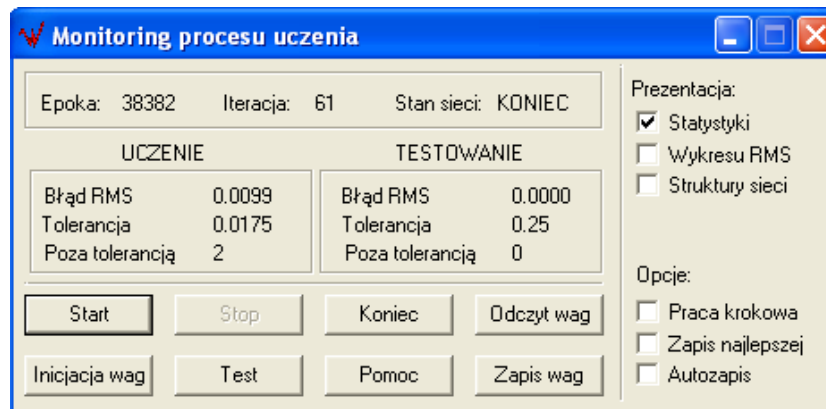
we	we	we	we	we	we	we	we	we	we	we	we	we	we	we	we	we	we	we	we	we	wy
x	x+1	x+2	x+3	x+4	x+5	x+6	x+7	x+8	x+9	x+10	x+11	x+12	x+13	x+14	x+15	x+16	x+17	x+18	x+19	y=x+20	
11	6	9	4	4	3	3	3	4	4	4	8	9	12	17	25	35	40	74	75	116	
6	9	4	4	3	3	3	4	4	4	8	9	12	17	25	35	40	74	75	116	170	
9	4	4	3	3	3	4	4	4	8	9	12	17	25	35	40	74	75	116	170	234	
4	4	3	3	3	4	4	4	8	9	12	17	25	35	40	74	75	116	170	234	257	
4	3	3	3	4	4	4	8	9	12	17	25	35	40	74	75	116	170	234	257	340	
3	3	3	4	4	4	8	9	12	17	25	35	40	74	75	116	170	234	257	340	297	
3	3	4	4	4	8	9	12	17	25	35	40	74	75	116	170	234	257	340	297	342	
3	4	4	4	8	9	12	17	25	35	40	74	75	116	170	234	257	340	297	342	299	
4	4	4	8	9	12	17	25	35	40	74	75	116	170	234	257	340	297	342	299	322	
4	4	8	9	12	17	25	35	40	74	75	116	170	234	257	340	297	342	299	322	281	
4	8	9	12	17	25	35	40	74	75	116	170	234	257	340	297	342	299	322	281	299	
8	9	12	17	25	35	40	74	75	116	170	234	257	340	297	342	299	322	281	299	289	
9	12	17	25	35	40	74	75	116	170	234	257	340	297	342	299	322	281	299	289	296	
12	17	25	35	40	74	75	116	170	234	257	340	297	342	299	322	281	299	289	296	292	

17	25	35	40	74	75	116	170	234	257	340	297	342	299	322	281	299	289	296	292	293
25	35	40	74	75	116	170	234	257	340	297	342	299	322	281	299	289	296	292	293	279
35	40	74	75	116	170	234	257	340	297	342	299	322	281	299	289	296	292	293	279	286
40	74	75	116	170	234	257	340	297	342	299	322	281	299	289	296	292	293	279	286	274
74	75	116	170	234	257	340	297	342	299	322	281	299	289	296	292	293	279	286	274	291

3.2. Struktura sieci neuronowej

Do prognozowania zaproponowano sieć jednokierunkową, trójwarstwową typu backpropagation o 20 wejściach (20 okresów pomiarowych) i jednym wyjściu. Liczby neuronów w warstwach ukrytych dobrano eksperymentalnie i wynoszą one 15 i 10 neuronów.

Warunkiem zakończenia procesu uczenia było uzyskanie błędu średniokwadratowego (RMS) o wartości poniżej 0,01. Okno z monitorowania przebiegu procesu uczenia sieci prognozującej natężenie we wtorek przedstawiono na rys. 5.



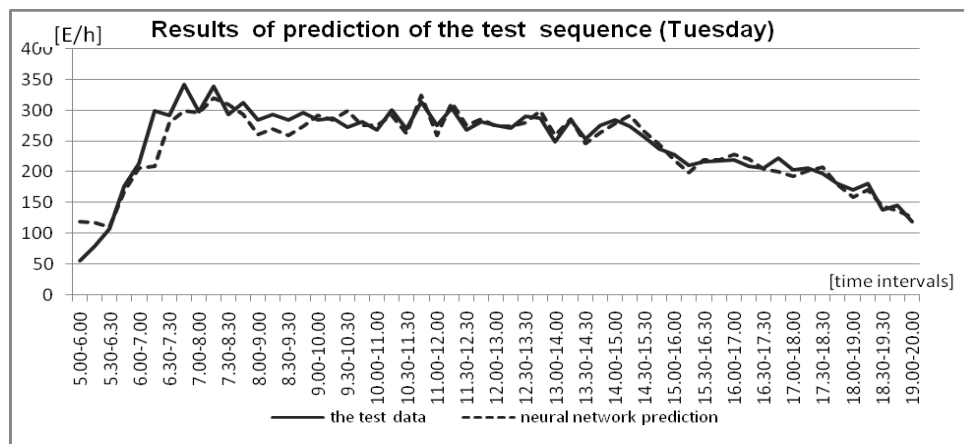
Rys. 4. Okno z monitoringu procesu uczenia

Fig. 5. The window of monitoring learning process

3.3. Test sieci. Predykcja za pomocą sieci neuronowej

Po wyuczeniu sieci zostały przetestowane. Zbiór testowy zawierał 60 wektorów po 20 kolejnych wartości natężenia. Na podstawie 20 danych prognozowana była kolejna, 21 wartość. Dane te nie wchodziły w skład ciągu uczącego. Średni błąd predykcji dla wtorku w godzinach 6.00-19.30 wynosi 3%.

Wyniki testów przedstawiono na rys. 6.



Rys. 6. Porównanie zmierzonych i prognozowanych wartości dla zbioru testowego – wtorek
 Fig. 6. Comparison of actual and predicted values for the testing rate – Tuesday

Analiza wykresu z rys. 6 wskazuje, że największy błąd prognozowania występuje dla godzin przedpołudniowych. Widać to również na wykresach z rys. 2 i 3. Różnice w wartościach natężenia po godzinie 13.00, są akceptowalne. Wyniki można by poprawić, dodając do ciągu uczącego wartości natężenia ruchu z większej liczby pomiarów lub zaproponować dodatkowe sieci.

4. PODSUMOWANIE

Otrzymane wyniki badań wskazują, że zaproponowane modele sieci neuronowych radzą sobie dość dobrze zarówno dla funkcji testowych, jak i dla danych pochodzących z przeprowadzonych rzeczywistych pomiarów na skrzyżowaniach. Świadczy to o dobrych właściwościach uogólniania, jakimi dysponują sieci neuronowe. Prognozowanie natężenia ruchu za pomocą otrzymanych sieci dało bardzo prawdopodobne wyniki. Średni błąd prognozy dla przedstawionych trzech skrzyżowań wyniósł niewiele ponad 4%, co świadczy o dobraniu odpowiednich parametrów uczenia oraz testowania. Tak niewielki błąd mieści się w dopuszczalnych granicach i może mieć bardzo wiele czynników powstania, które ciężko jest jednoznacznie określić. Mimo to, dysponując niewielką bazą danych wstępnych, udało się zbudować sieci dobrze oddające zjawisko natężenia ruchu na skrzyżowaniu.

Podsumowując można stwierdzić, że sieci neuronowe są dobrym narzędziem w procesie predykcji czasowych. Posiadając nieduży zbiór danych wejściowych, można dość dokładnie i szybko przewidzieć interesującą nas wartość w niedalekiej przyszłości. Dodatkowo cechą występującą w prognozowaniu natężeń ruchu na skrzyżowaniu jest okresowość, która ułatwia pracę i uczenie sieci. Jeżeli badane skrzyżowanie jest niezależne od nowego generatora ruchu pojazdów, to wyniki uzyskane podczas predykcji będą bardzo zbliżone do wyników rzeczywistych.

Uzyskanie dobrych rezultatów predykcji krótko- i długookresowej pozwala na używanie sieci neuronowych w systemach sterowania ruchem, które w swojej pracy mogą wymagać podania następującego, niezmiernego jeszcze pomiaru w celu uwzględnienia zmiany natężenia ruchu (detektory, pętla indukcyjna).

Bibliografia

1. Gaca S., Tracz M., Suchorzewski W.: Inżynieria ruchu drogowego. WKiŁ, Warszawa 2008.
2. Pamuła T., Król A.: Model systemu zarządzania ruchem pojazdów w obszarze miejskim z wykorzystaniem sieci neuronowych. Zeszyty Naukowe Pol. Śl., s. TRANSPORT, z. 67, nr kol. 1832, 2010.
3. Pamuła T.: Road traffic parameters prediction in urban traffic management systems using neural networks. *Transport Problems*, 2011.
4. Awad H.: Estimating traffic capacity for weaving segments using neural networks technique. *Applied Soft Computing* 4 (2004), pp. 395-404.
5. Ledoux C.: An urban traffic flow model integrating neural networks. *Transportation Research C*, Vol. 5, No 5, pp. 287-300, 1997
6. Hagrang O.: Estimation of Critical Gaps in Two Major Streams. *Transportation Research*, Vol. 34B, No 4, 2000, pp. 293-313.
7. Oh C., Ritchie S.G.: Recognizing vehicle classification information from blade sensor signature. *Pattern Recognition Letters*, Vol. 28, 2007, pp. 1041–1049.
8. Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: *Sieci neuronowe*. Tom 6. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.