

Teresa PAMUŁA, Aleksander KRÓL

MODEL SYSTEMU ZARZĄDZANIA RUCHEM POJAZDÓW W OBSZARZE MIEJSKIM Z WYKORZYSTANIEM SIECI NEURONOWYCH

Streszczenie. Artykuł przedstawia przegląd zastosowań sieci neuronowych w systemach zarządzania ruchem miejskim oraz propozycję systemu zarządzania, wykorzystującego sieci neuronowe. Opisane zostały te cechy sieci neuronowej, które mogą być przydatne w rozwiązywaniu zadań optymalizacji, związanych z opracowywaniem optymalnych strategii sterowania w miejskich systemach sterowania ruchem (UTC systems). W zaproponowanym modelu sieci neuronowe zastosowano do predykcji natężenia ruchu, opierając się na danych historycznych.

MODEL OF AN URBAN TRAFFIC MANAGEMENT SYSTEM UTILISING NEURAL NETWORKS

Summary. The article reviews neural networks applications in urban traffic management systems and presents a new approach for utilizing NN for devising a management system. It describes neural networks features, which allow them to be used to solve optimisation tasks involved in designing road traffic control strategies in urban traffic systems (UTC systems). In the proposed approach a neural network model is used for the prediction of road traffic intensity based on historical data.

1. WSTĘP

W większości miast na całym świecie zatory w ruchu drogowym stanowią coraz większy problem. Aglomeracja śląska i miasto Katowice, pomimo ciągłej przebudowy i modernizacji sieci dróg, nie stanowią tu wyjątku. Szybki wzrost liczby pojazdów powoduje wzrost natężenia ruchu drogowego, do którego nie jest przygotowana sieć ulic miejskich. Zjawisko to w konsekwencji wywołuje utrudnienia w ruchu komunikacji indywidualnej i zbiorowej, zmniejsza się czas przejazdu i regularność kursowania pojazdów; wzrastają koszty eksploatacji pojazdów.

W algorytmach sterowania i zarządzania ruchem można zastosować elementy sztucznej inteligencji. Ich implementacja pozwala uzyskać szybkie algorytmy wnioskowania, z uwzględnieniem specyficznych cech transportu drogowego. Proces sterowania przebiega

płynnie, a uzyskane wyniki optymalizacji mogą być lepsze niż otrzymywane za pomocą algorytmów regułowych.

Prace nad systemami tego typu trwają już od ponad 50 lat. Pierwszy tego typu system został oddany do użytku w Toronto [1]. Od tego czasu opracowano dużą liczbę modeli, ale ze względu na bardzo dużą złożoność zintegrowanych systemów zarządzania ruchem, nie udało się znaleźć rozwiązania, sprawdzającego się w każdych warunkach. Wiele z proponowanych rozwiązań skupia się na wybranym module lub algorytmie.

Współczesne systemy zarządzania korzystają z technologii takich dziedzin, jak: telekomunikacja i informatyka oraz metod zarządzania transportem. Tego typu systemy nazywane są Inteligentnymi Systemami Transportu (ITS – Intelligent Transportation System). Nazwa ITS została zaakceptowana na pierwszym światowym kongresie World ITS w Paryżu, w 1994. W USA opracowano specyfikację dotyczącą wymagań, które powinny spełniać Inteligentne Systemy Transportowe (ITS). Ostatnią wersję opublikowano w styczniu 2007 roku.

System zarządzania ruchem miejskim powinien uwzględniać następujące elementy[1]:

- istniejącą infrastrukturę drogową,
- prognozę zmian natężenia ruchu na zarządzanym obszarze,
- prognozę zmian rozłożenia ruchu, spowodowanych zmianą jego organizacji, na przykład z powodu imprez masowych, kolizji i innych sytuacji wyjątkowych, powodujących zaburzenia płynności ruchu,
- przepustowość dróg i ulic na odcinkach między skrzyżowaniami,
- przepustowość skrzyżowań,
- poziom bezpieczeństwa ruchu,
- wpływ zmian w organizacji ruchu na zyski/straty czasu poszczególnych grup użytkowników, zwłaszcza użytkowników komunikacji zbiorowej,
- koszty inwestycyjne, eksploatacyjne, wynikające z wprowadzenia i funkcjonowania systemu zarządzania ruchem miejskim,
- pojemność komunikacyjną obszaru.

Dodatkowymi parametrami, które mogą być brane pod uwagę przy optymalizacji sterowania i zarządzania są parametry odpowiadające za płynność ruchu oraz przepustowość. Płynność ruchu zależy od:

- strat czasu na poszczególnych skrzyżowaniach,
- liczby zatrzymań pojazdów,
- długości kolejek na pasach dojazdowych do skrzyżowań,
- rozkładu strat czasu (np. odchylenie standardowe),
- rozkładu długości kolejek.

W algorytmach zarządzania ruchem drogowym coraz częściej stosowane są metody sztucznej inteligencji, takie jak: logika rozmyta, algorytmy genetyczne czy sieci neuronowe [2,3].

2. CECHY SIECI NEURONOWYCH

Poniżej przedstawione zostały cechy sieci neuronowych, które można wykorzystać w różnych elementach i modułach inteligentnego systemu zarządzania ruchem miejskim.

- Klasyfikacja i rozpoznawanie – sieć uczy się podstawowych cech prezentowanych wzorców i na tej podstawie podejmuje odpowiednią decyzję klasyfikacyjną.

- Aproksymacja – sieć może pełnić rolę aproksymatora funkcji wielu zmiennych.
- Asocjacja – sieć zapamiętuje zbiór wzorców w taki sposób, aby po zaprezentowaniu nowego wzorca odpowiedzią sieci było wskazanie zapamiętanego wzorca, najbardziej podobnego do nowego.
- Grupowanie danych – sieć samoczynnie wykrywa podobieństwa w przetwarzanych danych.
- Predykcja – przewidywanie przyszłych realizacji albo cech statystycznych procesu stochastycznego.
- Mała wrażliwość na błędy (szумы) w zbiorze danych – w klasycznym programie komputerowym błąd danych może prowadzić do całkowicie błędnych wyników, sieć potrafi tego typu błąd pominąć.
- Zdolność do efektywnej pracy po częściowym uszkodzeniu sieci, np. usunięcie kilku neuronów lub połączeń między nimi (w przypadku realizacji sprzętowej).

3. PRZEGLĄD ZASTOSOWAŃ SIECI NEURONOWEJ W SYSTEMACH STEROWANIA I ZARZĄDZANIA RUCHEM

Najczęściej wykorzystywaną cechą sieci neuronowych jest możliwość predykcji różnych parametrów ruchu, takich jak np.: przepustowość, natężenie ruchu czy długość kolejki, na podstawie danych historycznych. Systemy sterowania ruchem I generacji, np. TRANSYT wykorzystują zbiór planów sterowania o parametrach wyznaczonych w trybie off-line na podstawie danej pory dnia (stała długość cyklu). Systemy sterowania II generacji mają już procedurę optymalizacji w trybie on-line, która korzysta z prognozowanych wartości natężenia ruchu w czasie 5-10 min, poprzedzającym wprowadzenie obliczonego planu sterowania, np. RTOP (stała długość cyklu).

Systemy sterowania III generacji umożliwiają optymalizację w trybie on-line na podstawie prognozy natężenia ruchu rejestrowanego w okresie 3-6 min, poprzedzającym wybór planu sterowania (zmienna długość cyklu), a systemy sterowania IV generacji – plany sterowania dostosowywane są do aktualnego stanu natężeń ruchu, a nie do wartości prognozowanych, ewentualnie prognozowanych w przedziale kilku sekund.

Przykładem może być system SCOOT, który do prognozowania długości kolejek pojazdów na kolejnym skrzyżowaniu wykorzystuje profile intensywności ruchu (straty czasu i zatrzymania pojazdów), aktualizowane co kilka sekund. Minimalizacja długości kolejki odbywa się przez zmianę splitów, offsetów i długości cykli.

W trójpoziomym, adaptacyjnym systemie sterowania miejskimi sieciami skrzyżowań UTOPIA-SPOT kluczem do procesu optymalizacji jest dokładna estymacja i predykcja strumieni ruchu, wykonywana za pomocą 3 typów detektorów. Za monitorowanie, diagnostykę i nadzór nad optymalizacją sieci skrzyżowań objętych systemem odpowiedzialna jest jednostka nadrzędna UTOPIA. Poziom niższy to sterownik nadrzędny SPOT. Na najniższym poziomie znajduje się sterownik lokalny.

3.1. Wykorzystanie sieci neuronowej do wyznaczania długości kolejki na wyjściu połączenia

Autorzy rozwiązania[3] przyjęli założenie, że długość kolejki w chwili $t+1+j$ jest funkcją:

$$lq(t+1+j)=f(lq(t+j), A(t+j), A(t-1+j), \dots, A(t-\tau+j), D(t+j)),$$

gdzie:

- $lq(t+j)$ – długość kolejki na wejściu połączenia w czasie $t+j$,
- $D(t+j)$ – natężenie na wyjściu połączenia w czasie $t+j$,
- $A(t+j)$ – natężenie na wejściu połączenia w chwili $t+j$,
- $A(t-1+j), \dots, A(t-\tau+j)$ – natężenia na wejściu połączenia w okresie poprzedzającym τ ,
- t – wartość początkowa okna czasowego H , j – długość okna czasowego.

Zmienne $lq(t+j)$, $D(t+j)$, $A(t+j)$, $A(t-1+j), \dots, A(t-\tau+j)$ są jednocześnie wejściami sieci neuronowej.

Wartość funkcji (wyjście sieci neuronowej) – $lq(t+j+1)$ to prognozowana długość kolejki w chwili $t+j+1$.

Sieć neuronowa spełnia rolę aproksymatora funkcji wielu zmiennych, realizując funkcję nieliniową o postaci $y=f(x_1, x_2, \dots, x_n)$.

3.2. Wykorzystanie sieci neuronowej do wyznaczania przepustowości drogi wielopasmowej – modyfikacja metody HCM2000

W tym przypadku sieć neuronowa została zastosowana do obliczenia przepustowości drogi wielopasmowej[3]. Przyjęto założenie, że przepustowość drogi wielopasmowej zależy od minimalnej i maksymalnej liczby zmian pasów, prędkości swobodnego przepływu pojazdów, długości badanego odcinka oraz liczby pasów. Strukturę sieci neuronowej przedstawiono na rys. 3.

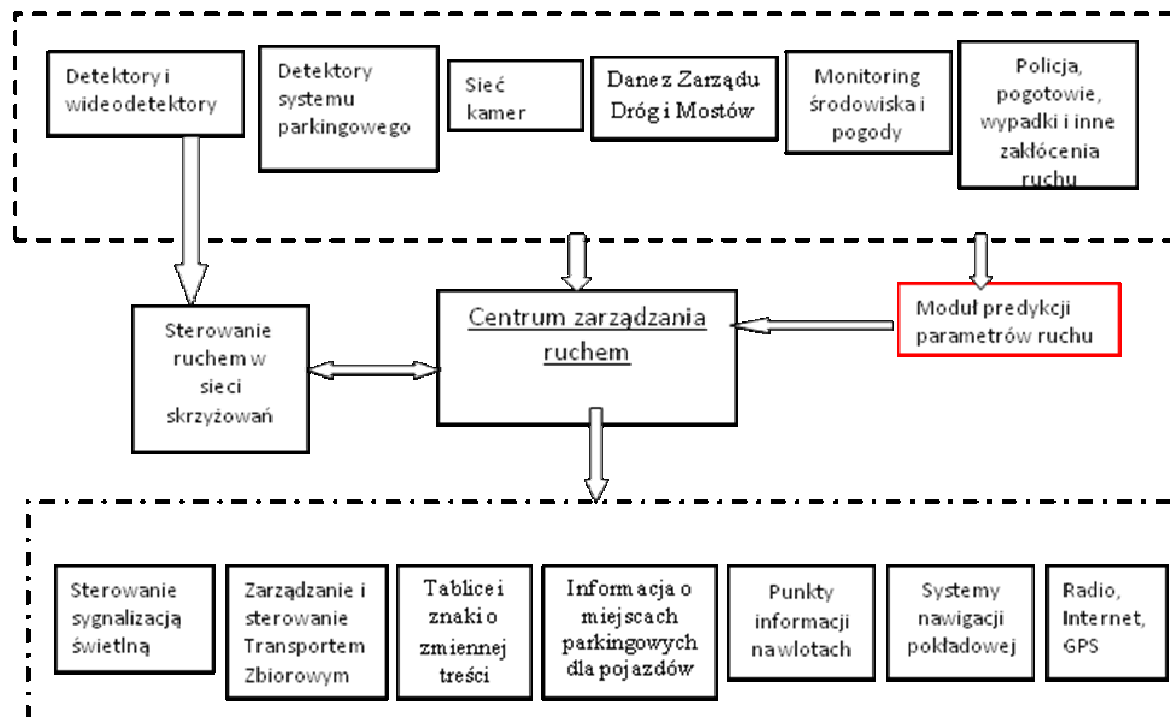
□ Wejścia sieci

- N_{wmin} – minimalna liczba zmian pasów
- N_{wmax} – maksymalna liczba zmian pasów
- S – prędkość swobodnego przepływu pojazdów
- L – długość badanego odcinka
- N – liczba pasów
- VR – współczynnik o wartościach 0,1 – 0,8, reprezentujący stosunek liczby zmian pasów do maksymalnej liczby zmian pasów dla badanego odcinka

□ Wyjście - C (przepustowość)

4. MODEL SYSTEMU ZARZĄDZANIA RUCHEM MIEJSKIM

Model współczesnego systemu zarządzania ruchem z zaproponowanym modułem predykcji, wykorzystującym sieć neuronową przedstawiono na rys. 1.



Rys. 1. Schemat systemu zarządzania ruchem miejskim


Fig. 1. Traffic management system scheme

W module predykcji do prognozowania natężenia ruchu zastosowano sieć neuronową.

Przyjęto następujące założenia:

- pomiary parametrów ruchu natężenia wykonywane w równych odstępach czasu stanowią szereg czasowy,
- jeśli wartości w takim szeregu zmieniają się cyklicznie, to na tej podstawie można dokonać predykcji wartości niezmierzonej jeszcze w danej chwili czasu,
- okno czasowe – dane historyczne, na podstawie których można przewidzieć kolejną wartość szeregu stanowią okno czasowe,
- predykcja krótkoterminowa – dotyczy zazwyczaj jednej lub kilku wartości wprzód,
- predykcja długoterminowa – zasięgiem swym obejmuje dłuższe okresy pomiarowe.

Idea zaproponowanej predykcji danych z wykorzystaniem okna czasowego i sieci neuronowej przedstawiona została na rys. 2. Sieć neuronowa umożliwi uzyskanie szybkiej prognozy krótkoterminowej (do 5 sek.), która ma istotny wpływ na sposób sterowania ruchem w sieci ulic.



Rys.2. Okno czasowe – wejście sieci neuronowej

Fig.4. Time window – input of neural network

Przyjęto założenie, że natężenie ruchu w badanym miejscu w poniedziałek, wtorek, środę i czwartek będzie podobne. W sobotę, ze względu na zakupy w supermarketach, natężenie ruchu będzie inne niż w niedzielę. Z obserwacji wynika również, że w piątek, z powodu wyjazdów weekendowych, natężenie ruchu ma inny rozkład niż w pozostałe dni tygodnia. W związku z tym, zaproponowano cztery sieci neuronowe, odpowiadające dniom tygodnia: sobota, niedziela, poniedziałek i piątek.

Cykle dobowe podzielono na okna czasowe o długości 60 sekund z krokiem 5 sekund, co w sumie daje 12 wartości. Ciąg uczący będzie liczył 1440(24x60) okien czasowych, każde po 12 wartości.

5. PODSUMOWANIE

Sieć neuronowa umożliwia uzyskanie dobrych rezultatów dla predykcji krótkookresowej. Może być, więc wykorzystana w systemach zarządzania i sterowania ruchem, które do procesu optymalizacji wymagają uwzględnienia niezmiernego wcześniej parametru (np. natężenia, długości kolejki). Badania celowości i skuteczności zastosowania sieci neuronowej zostaną przeprowadzone na modelu symulacyjnym, z wykorzystaniem oprogramowania Vissum oraz w środowisku Delphi dla wybranego obszaru miasta Katowice.

Bibliografia

1. Gaca S., Tracz M., Suchorzewski W.: Inżynieria ruchu drogowego, WKiŁ Warszawa 2008.
2. Wa'el H. 'Awad: Estimating traffic capacity for weaving segments using neural networks technique, Applied Soft Computing 4 (2004), pp.395–404.
3. Corinne Ledoux: An urban traffic flow model integrating neural networks, Transportation Research C, vol. 5, no 5, pp.287-300, 1997.
4. F.Boillot, S.Midenet, J.Pirrelee: The real-time urban traffic control system CRONOS, Transportation Research, 2006.

Recenzent: Prof. dr hab. inż. Romuald Szopa