

PRZEGLĄD ZASTOSOWAŃ SIECI NEURONOWYCH W TRANSPORCIE

Streszczenie

Zdolność sieci neuronowej do odwzorowania nieliniowych zależności między zmiennymi opisującymi zachowanie obiektów oraz możliwość opracowania efektywnej konfiguracji sprzyja zastosowaniom w transporcie. W artykule przedstawiono reprezentatywne przykłady z zakresu: predykcji parametrów ruchu drogowego, sterowania ruchem drogowym, pomiarów parametrów ruchu, zachowania kierowców i prowadzenia autonomicznych pojazdów, ekonomii i polityki transportowej oraz omówiono własności proponowanych rozwiązań. Najczęściej wybieranymi sieciami neuronowymi są jednokierunkowe wielowarstwowe, trenowane z użyciem algorytmu propagacji wstecznej. W przeglądzie wzięto pod uwagę artykuły opublikowane w czasopiśmie w ciągu ostatnich pięciu lat.

WSTĘP

Modele rozwiązań transportowych obejmują często złożone i nieliniowe zależności między zmiennymi odwzorowującymi ich, zwykle dynamicznie zmieniające się, zachowanie. Zastosowanie metod sztucznej inteligencji łączących w sobie elementy uczenia się, adaptacji i samoorganizacji pozwala efektywnie podjąć opracowanie takich modeli. Sztuczne sieci neuronowe oraz ich programowe lub sprzętowe realizacje stanowią dominującą reprezentację algorytmów obliczeniowych związanych ze sztuczną inteligencją.

Sieci neuronowe zaproponowane zostały w latach 60 tych XX wieku, a w zagadnieniach związanych z transportem zaczęto je stosować w latach 90. Znaczące zainteresowanie potwierdza przegląd zastosowań sieci wykonany w 1995 przez Dougherty'ego [1]. Autor wyróżnia dziewięć dziedzin zastosowań sieci: ocena zachowań kierowców, określanie parametrów ruchu i rozkładów podróży, ocena nawierzchni dróg, detekcja i klasyfikacja pojazdów, analiza przebiegów ruchu i wykrywanie zdarzeń, optymalizacja tras podróży, prognozowanie parametrów ruchu, sterowanie ruchem drogowym oraz polityka i gospodarka transportowa. Opisuje kilkadziesiąt reprezentatywnych opracowań w tych dziedzinach.

Od połowy lat 90 tych notuje się po kilkadziesiąt nowych pozycji w czasopiśmie i podobną liczbę w materiałach konferencyjnych. M.G. Karlaftis i E.I. Vlahogianni w 2011 porównali zakres wykorzystania tradycyjnych metod statystycznych i sieci neuronowych w badaniach zagadnień w transporcie [2]. Zaproponowali podział tematyki zastosowań na sześć grup zagadnień: analiza ruchu, zarządzanie infrastrukturą, utrzymanie ruchu, planowanie, ochrona środowiska, bezpieczeństwo i zachowanie uczestników ruchu. Podział jest zbieżny z wcześniejszym, akcentuje wzajemne powiązanie problemów np. związanych z określeniem parametrów ruchu, detekcją pojazdów i wykrywaniem zdarzeń. Wdrażanie zintegrowanych systemów zarządzania i sterowania ruchem, tzw. ITS (Intelligent Transport System) wymusza wiązanie zagadnień, stąd postępujące łączenie problemów badawczych. Po 2010 roku notuje się zainteresowanie nowym tematem badawczym – sterowaniem ruchem autonomicznych pojazdów.

W artykule proponuje się wyróżnienie następujących grup tematów badawczych do opracowania, których stosowane są sieci neuronowe:

- predykcja parametrów ruchu drogowego,
- sterowanie ruchem drogowym,
- pomiary parametrów ruchu,
- zachowanie kierowców i prowadzenie autonomicznych pojazdów,

- utrzymanie infrastruktury transportowej,
- ekonomia i polityka transportowa.

Przedstawione zostaną reprezentatywne przykłady wykorzystania i opisane własności uzyskanych rozwiązań modelowych lub obliczeniowych opublikowane w ciągu ostatnich pięciu lat w czasopiśmie.

1. WŁASNOŚCI SIECI NEURONOWYCH

Sztuczna sieć neuronowa przygotowana w postaci programu lub układu sprzętowego realizuje obliczenia z wykorzystaniem zbioru uporządkowanych warstwowo prostych elementów modelujących działanie neuronów [3]. Wyróżniającą cechą sieci neuronowych jest zdolność do odwzorowania nieliniowych zależności między zmiennymi opisującymi zachowanie modelu. Odwzorowanie uzyskuje się w toku uczenia sieci bez konieczności dogłębnej analizy własności funkcji wiążących zmienne opisujące zachowanie. W przypadku odwzorowania dynamicznych zależności niepotrzebne są założenia o stałości dynamiki zmian, które często stanowią barierę przy wykorzystaniu metod statystycznych do modelowania. Sieci neuronowe pozwalają zamodelować zachowanie systemów o bardzo złożonej dynamice działania. Ważniejsze własności sieci neuronowych to:

- 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 realizując funkcję nieliniową postaci $y=f(x_1, x_2, \dots, x_n)$,
- 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 prezentowanych danych,
- mała wrażliwość na błędy (szumy) w zbiorze danych,
- zdolność do efektywnej pracy po częściowym uszkodzeniu sieci.

Niedogodnością rozwiązań obliczeniowych opartych na sieciach neuronowych jest powiązanie uzyskanego wyniku z metodą uczenia sieci. Właściwy dobór ciągu uczącego i sposobu doboru

parametrów neuronów stanowi o sukcesie modelowania. Nie opracowano zasad doboru konfiguracji sieci dla uzyskania założonych własności modelowania. Prezentowane w literaturze przykłady sieci opracowane zostały w toku eksperymentów na podstawie ogólnych przesłanek uzyskanych z badań wcześniej wykonanych konfiguracji. W przeważającej liczbie przykładów stosowane są wielowarstwowe sieci jednokierunkowe. Sieci zawierają, poza warstwami wejściową i wyjściową, od jednej do kilku warstw ukrytych. Podstawowymi algorytmami uczenia sieci (aktualizacji wag neuronów) są algorytmy spadku gradientowego, przede wszystkim algorytm propagacji wstecznej. Nieliczne rozwiązania oparte są na sieciach rekurencyjnych lub sieciach Kohonena (SOM samoorganizujące się mapy).

2. ZASTOSOWANIE SIECI NEURONOWYCH

Sieci neuronowe w transporcie wykorzystywane są do:

- klasyfikacji danych,
- aproksymacji zależności funkcyjnych,
- analizy szeregów czasowych.

Wymieniona klasyfikacja tematów badawczych wskazuje, że każda grupa będzie miała specyficzną metodykę opracowania sieci związaną z dziedziną wykorzystania – tabela 1.

Tab 1. Zadania obliczeniowe realizowane przez sieć neuronową

Grupa zastosowań sieci neuronowych	Klasyfikacja danych	Aproksymacja zależności funkcyjnych	Analiza szeregów czasowych
predykcja parametrów ruchu drogowego			x
sterowanie ruchem drogowym		x	x
pomiary parametrów ruchu	x	x	
zachowanie kierowców i prowadzenie autonomicznych pojazdów	x	x	x
utrzymanie infrastruktury transportowej	x		x
ekonomia i polityka transportowa	x		x

Przedstawiony w artykule przegląd opracowano na podstawie bibliografii zastosowań sieci neuronowych w transporcie. Wybór reprezentatywnych przykładów wykorzystania wykonano spośród ponad 150 pozycji literatury opublikowanych w czasopiśmie w latach 2010-2015.

2.1. Predykcja parametrów ruchu drogowego

Zadania predykcji parametrów ruchu realizowane są dla systemów lokalnego sterowania, sterowania na ciągach ulic jak i dla potrzeb zarządzania ruchem. Definiowane są przez horyzont czasowy predykcji i oczekiwaną dokładność. Metody oparte na sieciach konkurują z metodami statystycznymi.

Elementami różnicującymi przykłady wykorzystania sieci do predykcji są:

- sposób identyfikacji zadania prognozowania,
- rodzaj odpowiedzi sieci.

Identyfikacja obejmuje wybór parametrów i rozdzielczości wartości tych parametrów podawanych na sieć. Wybierane są takie

parametry jak: czas podróży, prędkość podróży, natężenie ruchu. Odpowiedzią sieci są kolejne wartości parametrów lub wskazania kierunku zmian tych parametrów.

W pracy [4] zaproponowano wykorzystanie rejestrowanych profili prędkości do predykcji średniego czasu podróży w sieci ulic miasta. Profile prędkości uzyskiwane są przez grupowanie i łączenie danych z detektorów ruchu. Taki zabieg pozwala zredukować liczbę danych na wejściu sieci. Uzyskano predykcję średniego czasu podróży do pół godziny wprzód.

Średnia prędkość podróży wrażliwa jest na zdarzenia drogowe z natury o charakterze losowym. Van Hinsbergen i zespół [5] zaproponowali zamodelowanie tej losowości z użyciem probabilistycznych sieci neuronowych. Sieci PNN pozwalają uchwycić „powolne trendy” zmian dla zakłóconych danych. Uzyskane wyniki są zbliżone z prognozami czasów podróży dla niezakłóconych ciągów ulic.

Predykcje wykonywane są z wykorzystaniem danych historycznych rejestrowanych w regularnych odstępach czasu. W rzeczywistości w przypadku ITS łatwiej pozyskać dane np. z systemów GSM ze znacznikami o szerokim zakresie wartości odstępów czasowych, które dostatecznie charakteryzują ruch. W pracy [6] zaproponowano wykorzystanie takich danych jako wejściowych na sieć dla uzyskania predykcji prędkości na ciągach skrzyżowań. Wstępne wyniki prognoz nie spełniły oczekiwań odnośnie błędów. Uzupełniono dane wejściowe o wartości przyspieszeń ruchu oraz o dane z sąsiednich segmentów sieci ruchu. Uzyskane wyniki potwierdzają przydatność danych z systemów GSM do predykcji lecz dane te muszą zostać uzupełnione o pochodne np. wartości przyspieszeń.

Często prognozowanym parametrem jest natężenie ruchu drogowego. Zespół K. Kumara [7] podaje na sieć ciąg historycznych wartości gęstości, prędkości ruchu oraz identyfikuje dzień tygodnia dla, którego wykonywana jest predykcja. Dla uzyskania mniejszych błędów strumień ruchu rozpatrywany jest jako strumień indywidualnie poruszających się pojazdów. Uzyskano poprawną predykcję dla horyzontu czasowego od 5-15 minut.

W pracy [8] przedstawiono metodę klasyfikacji szeregów czasowych natężenia przepływu ruchu ze względu na dzień tygodnia. Celem klasyfikacji jest predykcja natężenia ruchu w godzinach popołudniowych na podstawie danych o natężeniu w godzinach porannych.

Uzyskiwane błędy predykcji zestawiane są z błędami predykcji z użyciem analizy statystycznej. Użycie sieci neuronowych niejednznacznie potwierdza lepszą zdolność predykcji, stąd podejmuje się opracowanie hybrydowych rozwiązań. Zespół K. Yan'a [9] wykorzystał wygładzanie wykładnicze danych wprowadzanych na sieć neuronową, dodatkowo zastosowano algorytm Levenberga-Marquardta uczenia sieci. Wygładzanie pozwoliło znacznie poprawić działanie sieci i zmniejszyć błąd predykcji natężenia ruchu.

Złożenia metod obliczeniowych opartych na statystyce i sztucznej inteligencji zyskują popularność i stają się ważnymi tematami badań.

2.2. Sterowanie ruchem drogowym

Podejmowane są próby zastosowania metod obliczeniowych wykorzystujących sieci neuronowe w opracowaniach sterowników sygnalizacji świetlnej, w systemach sterowania obszarowego i zarządzania. Sieci pozwalają przetworzyć wspólnie dane historyczne jak i sygnały bieżące z czujników identyfikujących sytuację drogową na sterowanie przebiegiem ruchu drogowego.

Artykuł [10] prezentuje pozycję zagadnień związanych z sieciami w dziedzinie metod inteligencji obliczeniowej, podkreślając ich wagę. Autorzy zwracają szczególną uwagę na rozwiązania łączące sieci z logiką rozmytą, gdzie sieć generuje odpowiedzi ze zbioru rozmytego w miejsce pojedynczych wartości. Układy sterowania

oparte na sieciach rozmytych poprawiają sprawność sterowania o kilkanaście procent w porównaniu ze sterowaniem stałoczasowym. Danymi wejściowymi sieci są sygnały zajętości detektorów pojazdów na wlotach oraz wartości historyczne parametrów ruchu na tych wlotach.

Wprost do źródeł pomysłu sztucznego neuronu nawiązują autorzy pracy [11]. Sieć neuronowa modelująca system sterowania skrzyżowania uczonej przez eksperta - inżyniera ruchu. Przeszłość stanu skrzyżowania definiowana i modyfikowana jest na podstawie doświadczenia eksperta. Symulacje i porównanie ze strategią sterowania MOVA (Microprocessor Optimised Vehicle Actuation) dowodzą o przewadze takiego rozwiązania sterowania.

2.3. Pomiary parametrów ruchu

Obraz sytuacji drogowej w skali działania ITS dobrze oddają macierze podróży, stąd wiele prac prezentuje metody określania wartości macierzy na podstawie niepełnych lub zakłóconych danych z czujników pomiarowych. Ważnym problemem dla zarządzania jest wykrywanie zdarzeń drogowych, które prowadzą do zaburzeń nawet w skali całego obszaru ruchu.

Zespół Lorentzo'a [25] opracował rozwiązanie sieci generującej wartości macierzy podróży na podstawie natężeń ruchu między węzłami sieci ulic. Dane z czujników zredukowane są z wykorzystaniem analizy głównych składowych i podawane na wejścia wielowarstwowej sieci. Wytrenowana sieć pozwala w czasie prawie rzeczywistym generować wartości macierzy podróży dla bieżącego zarządzania ruchem. W pracy [26] zaproponowano rozwiązanie sieci generującej krótkoterminową prognozę prędkości poruszania się na podstawie bieżących danych z czujników zatłoczenia oraz pozycji pojazdu i pory dnia. Sieć została wytrenowana z użyciem danych historycznych i modeluje macierz podróży w badanym obszarze.

Autorzy rozwiązania przedstawionego w artykule [27] wykorzystują sieć do łączenia danych z czujników drogowych i mobilnych stacji pomiarowych zainstalowanych w samochodach. Wytrenowana sieć odwzorowuje parametry ruchu na całym badanym obszarze. Dzięki wykorzystaniu zdolności sieci do aproksymacji niewielka liczba danych z samochodów pomiarowych bardzo efektywnie wspomaga określenie obrazu ruchu.

W pracach [28, 29] zaproponowano odwzorowanie stopnia zagrożenia wypadkami w badanym obszarze sieci drogowej. Jako czynniki sprzyjające wypadkom przyjęto: temperaturę, wilgotność warunków pogodowych, porę dnia oraz historyczne dane o wypadkowości na odcinkach dróg sieci. Wykorzystano zdolność do łączenia różnego rodzaju danych przez sieć neuronową.

2.4. Zachowanie kierowców i prowadzenie autonomicznych pojazdów

Postrzeganie sytuacji drogowej, osąd i podejmowanie decyzji w ruchu drogowym przez kierowców podlega wpływowi bardzo wielu czynników stąd tradycyjne modelowanie jest trudne do wykonania. Badania w tej grupie tematycznej koncentrują się na problemach zapewnienia bezpieczeństwa kierowcom oraz sterowania ruchem pojazdów bez udziału człowieka.

Problem zapewnienia bezpieczeństwa rozpatrywany z punktu widzenia samego kierowcy czyli jego zdolności do prowadzenia jak i zewnętrznych uwarunkowań jazdy tj. zagrożeń pojawiających się podczas kierowania.

Tematy badawcze z zakresu sterowania ruchem pojazdu obejmują identyfikację przebiegu ruchu oraz wybrane reguły prowadzenia pojazdu przede wszystkim śledzenie poprzedzającego pojazdu i utrzymywanie trajektorii ruchu w obrębie pasa drogowego.

W przeważającej liczbie prac zdolność do prowadzenia pojazdów określana jest na podstawie sygnałów biologicznych rejestrowanych z użyciem czujników umieszczonych na ciele kierowcy.

W pracy [12] za reprezentatywne dla określenia poziomu stresu kierowcy uznano sygnały pomiaru przewodnictwa skórniego (ang. galvanic skin response GSR), przezroczystości skóry (ang. photoplethysmogram PPG). Do analizy użyto dwie konfiguracje sieci: wielowarstwową i rekurencyjną. Z kilkunastoprocentowym błędem udało się szacować poziom stresu.

Zespół M. Patel'a [13] określa poziom zmęczenia na podstawie zmienności bicia serca kierowcy. Szereg czasowy danych z elektroencefalografu podany został na wielowarstwową sieć neuronową. Uzyskano podobny poziom błędów jak w przypadku określania stresu. W opracowaniu [14] wykorzystano sieć PNN uzyskując zbieżne wyniki.

Pochodny zmęczeniu poziom zachowania uwagi w identyczny sposób badany jest przez autorów pracy [15]. Na podstawie przebiegu aktywności ECG dodatkowo przewidują zmiany poziomu uwagi w ciągu najbliższych 5 minut, co proponują wykorzystać do sygnalizacji niebezpieczeństwa kontynuowania jazdy.

Bez czujników na ciele kierowcy określany jest poziom rozpraszania uwagi w pracy [16]. Na podstawie danych o kierunku jazdy oraz kierunku zwracania głowy kierowcy podanych na rekurencyjną sieć neuronową udało się wyznaczyć związek z poziomem rozpraszania uwagi.

Dla określenia sposobu jazdy, wykrycia niebezpiecznych zachowań wykorzystywana jest analiza szeregów czasowych wielkości opisujących manewry wykonywane przez kierowcę. Zespół Chong'a [17] opracował rozmytą sieć neuronową generującą cechy poruszania się kierowcy na podstawie parametrów wykonywanych skrętów i sposobu prowadzenia pojazdu na pasie ruchu. Badano zachowanie podczas śledzenia poprzedzającego pojazdu i reakcje na przeszkody drogowe. W pracy [18] przyjęto za wystarczający parametr określający charakter jazdy sposób dostosowania prędkości do warunków jazdy. Wykorzystując wielowarstwową sieć przygotowano model zachowania kierowcy i przeprowadzono symulacje działania.

Trudny problem identyfikacji położenia pojazdu w relacji do innych uczestników ruchu lub infrastruktury drogowej rozwiązywany jest przez łączenie danych z różnych źródeł. Autorzy pracy [19] proponują złożenie danych z systemu wizyjnego i odbiornika systemu pozycjonowania przestrzennego (GPS). System wizyjny dostarcza syntetyczne dane w postaci opisu pola widzenia z zaznaczeniem dozwolonych obszarów poruszania się, a odbiornik GPS prezentuje ślad przemieszczania się. Sieć neuronowa wypracowuje decyzję o parametrach kolejnego ruchu pojazdu w pasie drogi. Inne podejście prezentuje zespół Borenovic'a [20], który w miejsce danych z odbiornika GPS zastosował wartości mocy sygnału odbieranego ze stacji bazowych GSM (ang. received signal strength – RSS). Takie rozwiązanie eliminuje napotykaną zwykle w gęsto zabudowanych obszarach trudności z odbiorem sygnałów GPS. Uzyskano dokładność pozycjonowania lepszą od 5 m co uznano za wystarczającą do lokalizacji pojazdów.

W pracy [21] względne położenia pojazdów określane są z użyciem rozmytej sieci. Sieć otrzymuje na wejściu przetworzone dane z kamery – opis cienia poprzedzającego pojazdu, oraz ze skanera otoczenia – położenie środka pasa ruchu. Wypracowuje sygnały ostrzeżenia przed opuszczeniem pasa i zbyt małą odległością do poprzedzającego pojazdu. W podobny sposób regulowana jest prędkość pojazdu dla uzyskania zadanej odległości od poprzedzającego pojazdu co przedstawiono w pracy [22].

Zagadnienie wspomagania prowadzenia pojazdu (nawigacji) podejmowane jest w pracach [23, 24]. Zdolność sieci do uogólniania zależności między danymi została wykorzystana do redukcji prze-

strzeni poszukiwania rozwiązania problemu znajdowania najkrótszej drogi w sieci ulic.

2.5. Ekonomia i polityka transportowa

W grupie tematów związanych z polityką transportową dominują zagadnienia prognozowania skutków decyzji w zakresie rozbudowy i świadczenia usług.

Autorzy w pracy [30] prezentują rozwiązanie problemu planowania rozbudowy portu kontenerowego. Zaproponowano konfigurację sieci, która optymalizuje kolejność realizacji zadań w planie rozbudowy ze względu na wysokość dostępnych środków inwestycyjnych. Zmiennymi są: montaż kolejnych elementów wyposażenia portu, generowany ruch drogowy, zmiany w infrastrukturze drogowej portu dla obsługi tego ruchu. Dodatkowo wykorzystano historyczne dane związane z podobnymi inwestycjami portowymi. Podobny temat w odniesieniu do budowy autostrad opracowany został przez M. Li i W. Chen'a [31]. Zaproponowana sieć generuje ocenę planowanej inwestycji na podstawie kosztów budowy, oddziaływania środowiskowego, zastosowanych systemów i polityki zarządzania. Uzyskany model służy do symulacji różnych wariantów budowy autostrad.

Efektywne świadczenie usług transportowych wymaga znajomości popytu na usługi oraz zarządzania dostępną podażą. Przykładami wykorzystania sieci do określenia popytu mogą być prace zespołów Yingjun'a [32] i Gonzales'a [33]. Yingjun prognozuje zapotrzebowanie na taksówki z użyciem falkowej sieci neuronowej. Danymi wejściowymi sieci są: liczba taksówek, współczynniki wpływu: na komfort obsługi, koszt usługi, prędkość. Gonzales podejmuje zadanie określenia preferencji komunikacyjnych mieszkańców na podstawie badań ankietowych i śledzenia podróży z użyciem aplikacji mobilnych. Znaczna liczba zebranych danych wymaga użycia efektywnego narzędzia do analizy stąd zastosowano sieci neuronowe do ekstrakcji syntetycznych danych o sposobie przemieszczania się mieszkańców.

Zbrane dane mogą służyć do usprawnienia zarządzania dostępem do usług transportowych. W pracy [34] zaproponowany został system rezerwacyjny oparty na sieci, która optymalizuje jego przepustowość i rentowność, regulując dostęp do niego. Danymi wejściowymi są: rozmiar i zajętość pojazdów, czas wjazdu, długość podróży.

WNIOSKI

Własności i możliwości sztucznych sieci neuronowych sprzyjają szerokiemu ich zastosowaniu w rozwiązywaniu problemów w transporcie. Przedstawione przykłady dowodzą efektywności rozwiązań. Zwraca uwagę brak prac z zakresu optymalizacji doboru konfiguracji sieci dla uzyskania zadanych parametrów działania. Wybrane konfiguracje to przede wszystkim wielowarstwowe jednokierunkowe sieci trenowane z użyciem algorytmu propagacji wstecznej. W celu polepszenia działania stosuje się redukcję liczby danych wejściowych.

BIBLIOGRAFIA

1. M. Dougherty: A review of neural networks applied to transport, *Transportation Research Part C* 3 (1995) 247–260
2. 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) 387–399
3. Tadeusiewicz R.: *Sieci neuronowe*. Akademicka Oficyna Wydawn. RM, Warszawa, (1993)
4. Kehagias D., Salamanis A., Tzovaras D.: Speed Pattern Recognition Technique for Short-Term Traffic Forecasting based on Traffic Dynamics, *IET Intelligent Transport Systems*, Vol. 9, No. 6, (2015), 646-653
5. Van Hinsbergen, C.P.I.J.; Hegyi, A.; van Lint, J.W.C.; van Zuylen, H.J.: Bayesian neural networks for the prediction of stochastic travel times in urban networks, *IET Intelligent Transport Systems*, vol.5, no.4, (2011) 259-265
6. Qing Ye; Szeto, W.Y.; Wong, S.C., Short-Term Traffic Speed Forecasting Based on Data Recorded at Irregular Intervals, *IEEE Transactions on Intelligent Transportation Systems*, vol.13, no.4, (2012), 1727-1737
7. Kranti Kumar, M. Parida, V.K. Katiyar, Short Term Traffic Flow Prediction for a Non Urban Highway Using Artificial Neural Network, *Procedia - Social and Behavioral Sciences*, Vol. 104, (2013), 755-764
8. Pamula T.: Classification and Prediction of Traffic Flow Based on Real Data Using Neural Networks, *Archives of Transport* 4/2012, pp. 519-529
9. Kit Yan Chan; Dillon, Tharam S.; Singh, J.; Chang, E.: Neural-Network-Based Models for Short-Term Traffic Flow Forecasting Using a Hybrid Exponential Smoothing and Levenberg-Marquardt Algorithm, *IEEE Transactions on Intelligent Transportation Systems*, vol.13, no.2, (2012), 644-654
10. Dongbin Zhao; Yujie Dai; Zhen Zhang: Computational Intelligence in Urban Traffic Signal Control: A Survey, *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, vol.42, no.4, (2012), 485-494
11. Box S., Waterson B.: An automated signalized junction controller that learns strategies from a human expert, *Engineering Applications of Artificial Intelligence*, Vol. 25, 1, (2012), 107-118
12. Singh R. R., Conjeti S., Banerjee R.: A comparative evaluation of neural network classifiers for stress level analysis of automotive drivers using physiological signals, *Biomedical Signal Processing and Control*, Vol.8, 6, (2013), 740-754
13. Patel M., Lal S.K.L., Kavanagh D., Rossiter P.: Applying neural network analysis on heart rate variability data to assess driver fatigue, *Expert Systems with Applications*, Vol. 38, 6, (2011), 7235-7242
14. Qichang He, Wei Li, Xiumin Fan, Zhimin Fei: Driver fatigue evaluation model with integration of multi-indicators based on dynamic Bayesian network, *IET Intelligent Transport Systems*, vol.9, no.5, (2015) 547-554
15. Larue, G.S., Rakotonirainy, A., Pettitt, A.N.: Predicting Reduced Driver Alertness on Monotonous Highways, *IEEE Pervasive Computing*, vol.14, no.2, (2015), 78-85
16. Wollmer, M., Blaschke, C., Schindl, T., Schuller, B., Farber, B., Mayer, S., Trefflich, B.: Online Driver Distraction Detection Using LongShort-Term Memory, *IEEE Transactions on Intelligent Transportation Systems*, vol.12, no.2, (2011), 574-582
17. Chong L., Abbas M. M., Flintsch A. M., Higgs B.: A rule-based neural network approach to model driver naturalistic behavior in traffic, *Transportation Research Part C: Emerging Technologies*, Vol. 32, (2013), 207-223
18. Xu, L., Hu, J., Jiang, H., Meng, W.: Establishing Style-Oriented Driver Models by Imitating Human Driving Behaviors, *IEEE Transactions on Intelligent Transportation Systems*, vol.16, no.5, (2015), 2522-2530
19. Souza J. R., Pessin G., Shinzato P. Y., Osorio F. S., Wolf D. F.: Vision-based waypoint following using templates and artificial neural networks, *Neurocomputing*, Vol. 107, 1 (2013), 77-86

20. Borenovic, M.; Neskovic, A.; Neskovic, N.: Vehicle Positioning Using GSM and Cascade-Connected ANN Structures, IEEE Transactions on Intelligent Transportation Systems, vol.14, no.1, (2013), 34-46
21. Chi-Feng Wu, Cheng-Jian Lin, Chi-Yung Lee: Applying a Functional Neurofuzzy Network to Real-Time Lane Detection and Front-Vehicle Distance Measurement, IEEE Transactions on Systems Man and Cybernetics, Part C, vol.42, no.4, (2012), 577-589
22. Lin Cai, Rad, A.B., Wai-Lok Chan: An Intelligent Longitudinal Controller for Application in Semiautonomous Vehicles, IEEE Transactions on Industrial Electronics, vol.57, no.4, (2010), 1487-1497
23. Zhang J., Zhao X., He X.: A Minimum Resource Neural Network Framework for Solving Multiconstraint Shortest Path Problems, IEEE Transactions on Neural Networks and Learning Systems, vol.25, no.8, (2014), 1566-1582
24. Nazemi A., Omid F.: An efficient dynamic model for solving the shortest path problem, Transportation Research Part C: Emerging Technologies, Vol. 26, (2013), 1-19
25. Lorenzo M., Matteo M.: OD Matrices Network Estimation from Link Counts by Neural Networks, Journal of Transportation Systems Engineering and Information Technology, Vol. 13, 4, (2013), 84-92
26. Jungme Park, Y.L. Murphey, R. McGee, J.G. Kristinsson, M.L. Kuang, A.M. Phillips: Intelligent Trip Modeling for the Prediction of an Origin-Destination Traveling Speed Profile, IEEE Transactions on Intelligent Transportation Systems, vol.15, no.3, (2014), 1039-1053
27. Naranjo J.E., Jiménez F., Serradilla F.J., Zato J.G.: Floating Car Data Augmentation Based on Infrastructure Sensors and Neural Networks, IEEE Transactions on Intelligent Transportation Systems, vol.13, no.1, (2012), 107-114
28. Deka L., Quddus M.: Network-level accident-mapping: Distance based pattern matching using artificial neural network, Accident Analysis & Prevention, Vol. 65, (2014), 105-113
29. Durduran S. S.: A decision making system to automatic recognize of traffic accidents on the basis of a GIS platform, Expert Systems with Applications, Vol. 37, 12, (2010), 7729-7736
30. Garcia T. R., Cancelas N. G., Soler-Flores F.: The Artificial Neural Networks to Obtain Port Planning Parameters, Procedia - Social and Behavioral Sciences, Vol. 162, (2014), 168-177
31. Chen M. Li, W.: Application of BP Neural Network Algorithm in Sustainable Development of Highway Construction Projects, Physics Procedia, Vol. 25, (2012), 1212-1217
32. Yingjun Y., Cui H., Shaoyang Z.: A prediction Model of the Number of Taxicabs Based on Wavelet Neural Network, Procedia Environmental Sciences, Vol.12, B, (2012), 1010-1016
33. Gonzalez P.A., Weinstein J.S., Barbeau S.J., Labrador M.A., Winters P.L., Georggi N.L., Perez R.: Automating mode detection for travel behaviour analysis by using global positioning systems enabled mobile phones and neural networks, IET Intelligent Transport Systems, vol.4, no.1, (2010), 37-49
34. Zhao Y., Triantis K., Teodorovic D., Edara P.: A travel demand management strategy: The downtown space reservation system, European Journal of Operational Research, Vol. 205, 3, (2010), 584-594.

THE REVIEW OF THE APPLICATIONS OF NEURAL NETWORKS IN TRANSPORT

Abstract

The neuron networks capability to map nonlinear functions of variables describing the behaviour of objects and the simplicity of designing their configuration favours the applications in transport. The paper presents representative examples in the scope of: prediction of road traffic parameters, road traffic control, measurement of road traffic parameters, drivers behaviour and autonomous vehicles, economy and transport policies. The features of the solutions are examined. Feedforward multilayer neural networks, trained using backpropagation, are the most often utilised configurations in transport applications. In the review was taken into account the articles published in journals over the past five years.

Autor:

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