

Andrzej SZARATA*
Politechnika Krakowska

ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH W DROGOWNICTWIE I KOMUNIKACJI

Streszczenie. Referat przedstawia wykorzystanie sztucznych sieci neuronowych w problematyce krótkoterminowych prognoz natężeń ruchu, estymacji więźby ruchu oraz badaniach grubości warstw nawierzchni drogowej. Stanowi on próbę pokazania możliwości wykorzystania sieci neuronowych w zagadnieniach praktycznych, związanych z drogownictwem.

ARTIFICIAL NEURAL NETWORKS IN TRANSPORT AND ROAD ENGINEERING

Summary. This paper presents possibility of using neural networks in short term traffic intensity forecasting, O-D matrix estimation and determining of width of road pavement. It is an attempt of presentation of neural networks in practice on various field of road engineering.


1. Istota sztucznych sieci neuronowych (SSN)

Powszechnie wiadomo, że komputery są dokładniejsze i szybsze w przetwarzaniu numerycznym od mózgu ludzkiego. Jednakże w wielu zadaniach obliczeniowych, takich jak rozpoznawanie mowy czy obrazów, mózg ludzki okazuje się bardziej skuteczny od komputera. Warto dodać, że mózg przewyższa efektywnością każdy superkomputer pomimo, że w tym procesie biologiczne neurony są wolniejsze od swych elektronicznych odpowiedników, bardziej skłonne do działania niedokładnego i niepoprawnego oraz prawie wszystkie są funkcjonalnie tego samego typu. Z punktu widzenia zasady działania mózg i komputer realizują podobne funkcje, tj. przetwarzają, gromadzą i odzyskują informacje. Zasadnicza różnica polega na odmiennym sposobie przetwarzania i gromadzenia informacji. Konwencjonalny komputer

*Opiekun naukowy: Prof. dr hab. inż. Andrzej Rudnicki.

gromadzi i pozyskuje informacje z komórek pamięci (np. RAM). Siła neuronów biologicznych tkwi w ich liczbie. W mózgu ludzkim jest ich ok. 10^{11} , a liczbę połączeń między nimi szacuje się na ok. 10^{15} [1]. Pomimo względnie długiego czasu aktywacji (szacuje się go na 10^6 razy dłużej niż czas działania pojedynczego elementu w układzie scalonym mikroprocesora [1]) równoległe przetwarzanie i rozproszone zapamiętanie informacji czyni z mózgu potężny układ obliczeniowy. Przykładem może być rozpoznawanie twarzy innego człowieka w czasie krótszym od 1 s. Sztuczny neuron (rys.1) może być traktowany jako przetwornik sygnałów działający według następującej zasady:

- Na wejściu przetwornika podawane są sygnały wejściowe w postaci wektora „ u ”.
- Sygnały te są mnożone przez odpowiednie współczynniki wag „ w ”.
- Ważone sygnały są odpowiednio sumowane w bloku sumatora – powstanie sygnału wyjściowego φ .
- Po uwzględnieniu wartości progowej, funkcja φ jest przetwarzana przez blok aktywacji. Może to być prosta funkcja liniowa, funkcja skoku jednostkowego, sigmoidalna czy tangensoidalna.
- Jako efekt końcowy uzyskujemy sygnał wyjściowy y .



Rys.1. Model sztucznego neurona [1]

Fig. 1. Artificial neurone model

Sztuczne sieci neuronowe, wzorowane na układach biologicznych posiadają zdolność do uczenia się i adaptacji. Uczenie sieci, z technicznego punktu widzenia, polega na odpowiednim doborze wartości współczynników wag $\{w_{ij}\}$ połączeń pomiędzy i -tymi i j -tymi elementami przetwarzającymi [1]. Najważniejszą cechą SSN jest zdolność do:

- uczenia i uogólniania zagadnień stochastycznych, dynamicznych lub nieliniowych,
- radzenia sobie z danymi obciążonymi błędami,
- dużej szybkości obliczeniowej.

Sieci neuronowe mają jednak poważne wady ograniczające ich zastosowanie:

- sieci wymagają dużej ilości danych wykorzystywanych w procesie uczenia i testowania,

- niemożliwe jest nadanie fizycznego znaczenia ukrytym warstwom i połączeniom pomiędzy neuronami,
- nigdy nie jesteśmy pewni, czy wyniki spełnią fizyczne ograniczenia rozważanego zagadnienia, tzn. że rozwiązanie jest wykonalne.

Możliwości sieci neuronowych w zakresie uczenia i uogólniania powodują, że sieci neuronowe znajdują zastosowanie w wielu zagadnieniach inżynierskich. W ciągu ostatnich kilku lat wiele razy próbowano wykorzystać SSN do rozwiązania problemów transportowych. W niniejszej pracy zostaną przedstawione trzy próby wykorzystania sieci neuronowych do:

- prognozowania natężenia ruchu,
- estymacji więzby ruchu wraz z rozkładem ruchu na sieć,
- badaniem grubości warstw nawierzchni drogowej.

2. Zastosowanie sztucznych sieci neuronowych w drogownictwie

2.1. Krótkoterminowe prognozy natężenia ruchu drogowego (opracowano na podstawie [3])

Efektywność zarządzania siecią uliczno-drogową znacznie wzrośnie, gdy będziemy dysponowali narzędziem pozwalającym na sprawne i możliwie najlepiej odpowiadające rzeczywistości prognozowanie natężenia ruchu ulicznego. Przykładem może być optymalizacja zielonej fali (w zależności od długości kolejki oczekujących pojazdów i intensywności przyjazdów następnych) czy sterowanie długością cyklu sygnalizacji świetlnej (uzależnionej od natężenia ruchu). Informacja o sytuacji ruchowej jest przetwarzana centralnie lub lokalnie. Dalsze rozważania będą próbą pokazania, jak zastosować sieci neuronowe do przewidywania potoków ruchu wykorzystując tylko dane z pomiarów lokalnych. Założono, że w wyznaczonych punktach sieci ulicznej możliwy jest pomiar długości kolumny pojazdów oczekujących na wlocie lub liczby pojazdów przejeżdżających przez skrzyżowanie w cyklu. W wielu dyscyplinach naukowych, takich jak fizyka czy biologia, próbuje się wnioskować własności nieznanego układu przez analizę zachowań rozważanego zbioru danych, w tym przewidywania zmian w czasie. Proces generujący dane z natężenia ruchu może być utożsamiany z czarną skrzynką posiadającą jedno wyjście $\{y_i\}$. Przedstawiony model predykcji jednoetapowej używa informacji ze zbioru $\{y_i\}$, które po przetworzeniu powinny dać nową wartość $y(t)^*$. Powyższy proces można opisać nieliniową funkcją wielu zmiennych:

$$y(t)=F[y(t-1),y(t-2), \dots ,y(t-n)] \quad (1)$$

gdzie: t – czas, n – liczebność próby.

Prognozowanie wymaga uzupełnienia funkcji $F(\)$ zbiorem danych z poprzednich pomiarów. Należy pamiętać, że natężenie ruchu jest uzależnione od pory dnia, dnia tygodnia, pory roku czy warunków pogodowych. Ponadto inaczej rzecz się ma na drodze szybkiego ruchu, a inaczej na ulicy w centrum miasta. Rozważano dwa rodzaje sieci neuronowych:

1. Pierwszy przypadek to jednokierunkowa sieć neuronowa bazująca na budowie wielowarstwowego perceptronu. Sieci neuronowe są najczęściej stosowane do prognozowania (przy założeniu że mamy do czynienia z funkcją rzeczywistą). Budowa sieci to: warstwa wejściowa z sigmoidalną funkcją przeskalowania danych i pojedyncza warstwa wyjściowa z liniową funkcją aktywacji. Architektura sieci wykorzystywanych do badań natężeń ruchu drogowego zawiera n danych wejściowych, h warstw ukrytych i tylko jedno wyjście. Wzorce $y(t-1)$, $y(t-2)$, $y(t-3)$ stanowią dane wejściowe. W warstwach ukrytych następuje przeskalowywanie danych funkcją sigmoidalną oraz przypisywanie wag poszczególnym połączeniom. Warstwa wyjściowa za pomocą funkcji aktywacji buduje estymowaną wartość $y(t)^*$

$$y(t)^*=w_0+\sum w_j\psi_j(\sum w_{ji}y(t-1)+w_{j0}) \quad (2)$$

gdzie: ψ_j – jest funkcją sigmoidalną przeskalowania,

w_{ji} – stanowi wagi połączeń pomiędzy warstwą wejściową a warstwami ukrytymi,

w_j – stanowi wagi połączeń pomiędzy warstwami ukrytymi a warstwą wyjściową.

2. Drugi przypadek to sieci radialne (stanowią alternatywne narzędzie dobrze spisujące się w zagadnieniach prognozowania). Sieci radialne stanowią wielowymiarową funkcję, która zależy od promienia $r=||x-c||$ będącego różnicą pomiędzy wektorem wejściowym X a założonym środkiem C . Mogą one być opisywane funkcją Gaussa:

$$\Phi(r)=\exp(-r^2/\sigma^2) \quad (3)$$

gdzie: σ^2 - parametr przeskalowujący

Sieci radialne składają się tylko z jednej warstwy ukrytej, a połączenia pomiędzy warstwą wejściową a ukrytą nie są wazone. Warstwa wyjściowa, podobnie jak w perceptronie, sumuje dane (tym razem wazone) i tym sposobem uzyskuje się szukaną wartość:

$$y(t)^*=w_0+\sum w_i\theta_i(\|x(t)-c_i\|) \quad (4)$$

gdzie: $x(t)=[y(t-1),y(t-2), \dots ,y(t-n)]^T$, c_i stanowią środki sieci radialnych.

Do przedstawionych architektur sieci konieczna jest duża baza danych, zarówno dla procesu uczenia jak i testowania. Dla tego celu stworzono matematyczny model opisujący zmiany natężenia ruchu drogowego w zależności od pory dnia. Jako dane uczące zastosowano 100 wzorców zmian natężeń ruchu wyznaczonych według przyjętego modelu dla losowo wybranej pory dnia.

Wnioski

Przedstawione techniki prognozowania krótkoterminowego wykazały swoje możliwości w rozwiązywaniu postawionych zadań i nie wymagały uwypuklenia dynamiki zmian natężenia ruchu. Ich dokładność jest porównywalna, jednakże sieci radialne dają lepsze osiągi i szybciej niż sieci jednokierunkowe osiągają zbieżność. Dużą różnicę w wynikach zaobserwowano, gdy liczba danych uczących została zredukowana ze względu na rozmiary zbiorów uczących. Taka sieć traciła zdolności uogólniania.

Wyniki pozwalają wyznaczyć prognozy ruchu, które mogą być wykorzystane w sterowaniu ruchem i zarządzaniu całego układu. Jednakże parametry predykcji wykorzystane w sieciach, mogą nie być optymalne dla konkretnych przypadków.

2.2. Estymacja więzby ruchu Źródło-Cel i rozkład ruchu na sieć (opracowano na podstawie [4])

Najwcześniejsze podejście służące do estymacji macierzy podróży za pomocą wyników natężeń ruchu w sieci bazują na modelach grawitacyjnych. Na przełomie lat 70. i 80. rozwinęło się kilka technik i podejść, m.in. maksimum prawdopodobieństwa, minimum niezgodności, maksymalizacja entropii. W rzeczywistej sieci pomiary ruchu są zwykle obarczone błędami i zaburzeniami różnej natury. Jeżeli więc estymacja więzby ruchu jest problemem nieliniowym, obciążonym błędami, to wydaje się, że najlepszym sposobem podejścia będzie sztuczna sieć neuronowa. W 1995 roku Fusco i Gori udowodnili, że sieci neuronowe o wstecznej propagacji błędów, zastosowane do przewidywania potoków ruchu, dają zadowalające wyniki w warunkach nie obciążonych różnego rodzaju zaburzeniami, ale są nieadekwatne w razie występowania zaburzeń (wypadek drogowy, awaria sygnalizacji). Tym sposobem możliwość generalizacji sieci jest ograniczona do reprodukcji wzorców danych, które nie były wcześniej zarejestrowane, ale opierających się na zależnościach zaobserwowanych podczas etapu uczenia sieci. Oczekiwana korzyść z zastosowania sieci neuronowych w estymacji więzby ruchu i rozkładu ruchu na sieć nie polega na dokładności estymacji, ale na uży-

skaniu rozwiązań zgodnych z fizyczną strukturą sieci ulicznej. Taka korzyść przemawiałaby za wykorzystaniem SSN w zróżnicowanych warunkach, szczególnie przy wykrywaniu zdarzeń drogowych, gdzie istotna jest szybka i dokładna detekcja incydu oraz zdolność do określenia wielkości obszaru, na który owe zdarzenie miało wpływ. Proponowana procedura bazuje na sprawdzeniu, czy obserwowane natężenie ruchu jest zgodne z natężeniem obliczonym przez założoną sieć neuronową. Opracowano dwie architektury sieci służące do estymacji więzby \dot{Z} -C i rozkładu ruchu na sieć:

- 1) pierwsza trójwarstwowa sieć neuronowa ze wsteczną propagacją błędów służy do rozwiązania zagadnień estymacji więzby ruchu na podstawie danych pomiarowych,
- 2) druga, trójwarstwowa sieć neuronowa ze wsteczną propagacją błędów służy do rozłożenia ruchu na sieć.

Proponowane rozwiązanie różni się znacznie od innych zastosowań sieci neuronowych, gdzie sieć neuronowa jest wyuczona na zbiorze danych uzyskanych z obserwacji rzeczywistych warunków panujących na drodze (uwzględniających istnienie zdarzeń drogowych). W przedstawianym rozwiązaniu sieć neuronowa jest wyuczona tak, aby wykryć warunki występowania zdarzeń drogowych, nawet jeśli nie zostały one wcześniej uwzględnione.

Analogia pomiędzy siecią uliczną a siecią neuronową może być wyraźnie uwidoczniiona w przypadku rozkładu ruchu na sieć. Pary Źródło-Cel (\dot{Z} -C) mogą być postrzegane jako neurony w warstwie wejściowej, a trasy symbolizują ukryte warstwy. Połączenie p_{ki} łączy pary \dot{Z} -C, a trasy reprezentują wybór zachowań użytkowników.

$$F_k = \sum_k p_{ki} q_i \quad (5)$$

gdzie: p_{ki} – element macierzy (więzby ruchu).

Znaczenie połączeń reprezentuje prawdopodobieństwo wybrania k -tej trasy łączącej i -tą parę \dot{Z} -C. Jako podstawę tego schematu przyjęto założenie, według którego wszystkie neurony wejściowe nie mogą być połączone ze wszystkimi neuronami warstwy ukrytej. W efekcie zbiór możliwych rozwiązań musi spełniać następujący warunek:

$$q_i = \sum_k \beta_{ik} F_k \quad (6)$$

W związku z tym możemy założyć (na podstawie znajomości topologii sieci komunikacyjnej), że niektóre połączenia będą miały wagę równą zero. Znajomość wag pozostałych połączeń będzie zależała od wartości skalarnej C_k przypisanej każdej trasie k , a określonej wartością połączeń f_h .


$$f_h = \sum_k \alpha_{hk} F_k \quad (7)$$

gdzie: α_{hk} – współczynnik, określa związek pomiędzy warstwą ukrytą a warstwą wyjściową.

Dla tak zbudowanej sieci neuronowej funkcja aktywacji przyjmie następującą postać:

$$y_i = g(\sum_k p_{ki} q_i - s) \quad (8)$$

Na rysunku 2 przedstawiono architekturę sieci neuronowej analizującej przyjętą sieć komunikacyjną.



Rys. 2. Uproszczona sieć neuronowa

Fig. 2. Simplified neural network

Estymacja więzby \dot{Z} -C i rozkład ruchu na sieć

Wstępne wykorzystanie SSN do rozwiązania problemu estymacji \dot{Z} -C i rozkładu ruchu na sieć przedstawiono na przykładzie Viterbo – średniej wielkości miasta w regionie Lazio (Włochy). Na uproszczonym układzie ulic utworzono 36 par \dot{Z} -C, 10 połączeń i 8 węzłów. Zbiór danych zawiera historyczne więzby ruchu q_i i zbiór potoków pojazdów f_h liczonych co 20 minut w okresach między $10^{20} - 14^{20}$ oraz między $17^{00} - 20^{40}$ przeciętnego dnia roboczego, na każdym z połączeń w sieci ulicznej. Jako zbiór uczący wykorzystano 23 pary \dot{Z} -C. O trudności w znalezieniu bazy danych zawierającej wystarczająco szeroki wachlarz warunków zewnętrznych świadczy fakt, że nawet w przypadku ciągłej detekcji zdarzeń na autostradzie (z dużą liczbą automatycznie zarejestrowanych danych) zaobserwowano tylko 31 incydentów. Alternatywne podejście zaleca dodanie losowych warunków do macierzy \dot{Z} -C. Ponieważ sieć jest uczona na wzorcach stworzonych przez istniejące macierze i odpowiadający im potok ruchu, uzyskujemy duży zbiór danych zawierających możliwie najwięcej informacji i nieregularności potoków ruchu. Dla estymacji więzby ruchu \dot{Z} -C zaprojektowano 3-warstwową sieć ze wsteczną propagacją błędów, posiadającą 10 neuronów w warstwie wejściowej, 42 neurony w warstwie ukrytej i 36 neuronów w warstwie wyjściowej 10 / 42 / 36. W przypadku rozkładu ruchu na sieć, układ warstw jest następujący 36 / 42 / 10. Autorzy projektu wyko-

nali badania na tych samych danych przy wykorzystaniu 4 rodzajów sieci ze wsteczną propagacją błędów:

- SSN1 tradycyjna sieć ze wszystkimi możliwymi połączeniami neuronów,
- SSN2 uproszczony model sieci, z wagami połączeń przyjętymi w sposób losowy,
- SSN3 uproszczony model sieci, z wagami wstępnie przyjętymi w zależności od wyboru połączenia (ścieżki) przez użytkowników,
- SSN4 model jak wyżej, lecz z narzuconymi wartościami wag.

Etap testowania więzby \dot{Z} -C przeprowadzono na danych nie wykorzystanych do procesu uczenia, natomiast dane wyjściowe porównano z wynikami uzyskanymi z tradycyjnych metod obliczeniowych (metoda Spiessa). Po przeanalizowaniu wyników obliczeń dla poszczególnych rodzajów sieci neuronowych można wnioskować, iż:

- średni procentowy błąd SSN1 jest niski zarówno w estymacji więzby ruchu, jak i rozkładu ruchu na sieć (odpowiednio 5,8% i 3,5%). Należy tu pamiętać o relatywnie niewielkim zbiorze uczącym,
- suma popytu uzyskana jako wartość wyjściowa jest zbliżona do rzeczywistego potoku ruchu (różnica wynosi 1,8% dla estymacji więzby ruchu i 0,1% dla rozkładu ruchu na sieć),
- SSN2 i SSN3 dają te same wyniki, co pokazuje, że sieć neuronowa jest w stanie osiągnąć zbliżone wyniki niezależnie od założonych wag wyjściowych,
- SSN4, w której wstępne wartości wag były narzucone, wykazuje znacznie lepsze wyniki od np. SSN2 posiadając średni błąd procentowy 14,6% i 3,7% odpowiednio dla estymacji (\dot{Z} -C) i rozkładu ruchu na sieć.

Uwagi

Podejście neuronowe było testowane zarówno dla estymacji macierzy \dot{Z} -C i rozkładu ruchu na sieć, mimo że podejście to jest bardziej użyteczne przy rozwiązaniu pierwszego z problemów. Wadą takiego rozwiązania jest konieczność długotrwałych obliczeń nawet dla relatywnie prostych sieci komunikacyjnych. Etap uczenia był przeprowadzony w różnych „stanach systemu” obserwowanych podczas różnych okresów. Zachowanie użytkowników ulegało zmianom w zależności od określonego przedziału czasowego (zmiana motywacji), co w efekcie prowadziło do zmian obciążenia układu.

2.3. Neuronowa metoda interpretacji wyników badań grubości warstw nawierzchni z penetroradaru (opracowano na podstawie [5])

Praca nawierzchni drogowej jest procesem złożonym. Zniszczenia nawierzchni nie pojawiają się jednocześnie na całej długości drogi, lecz tylko w niektórych jej strefach. Jest to spowodowane zmiennością właściwości materiału oraz między innymi zmienną grubością warstw w przekroju podłużnym. Wiele z obecnie stosowanych metod konstrukcji nawierzchni nie uwzględnia zmienności tych parametrów, dzieje się tak między innymi z powodu ograniczonej liczby danych pomiarowych. Dotychczas najczęściej stosowaną metodą do uzyskania informacji o grubościach warstw nawierzchni było wycinanie lub odwiercanie próbek. Jednak, aby uzyskać pełny obraz zmienności grubości warstw, należałoby wykonać wiele odwiertów wzdłuż drogi. Od kilku lat do analiz struktury nawierzchni stosuje się penetroradary. Pozwalają one na badanie nawierzchni bez fizycznej ingerencji urządzenia w strukturę warstw. Dane uzyskane z penetroradaru są przetwarzane na grubości warstw nawierzchni. Uzyskiwane wyniki porównuje się z danymi uzyskanymi przez wykonanie odwiertów lub wykopów kontrolnych. Na tej podstawie można określić stopień dokładności pomiaru i przetworzenia danych. W celu automatycznego przetwarzania danych na grubości warstw zastosowano sieć neuronową z algorytmem uczenia ciągłego. Sieć ta jest trójwarstwowym perceptronem składającym się z 7 neuronów w warstwie wejściowej, 3 neuronów w warstwie ukrytej oraz 2 wyjść. Sieć neuronowa wykorzystuje zdolność do uogólniania, czyli znajdowania relacji dane-wynik nie tylko dla znanych wzorców, ale również do interpolacji poprawnych wyników dla nieznanymi danych (tzn. danych nie wykorzystanych w procesie uczenia). W zastosowanym przypadku sieć została nauczona kojarzenia głębokości wnikania sygnału radarowego z prędkością rozchodzenia się fali w warstwie podczas odczytu danych pomiarowych. Ponieważ do nauczania sieci potrzebna jest bardzo duża liczba przykładów, które trudno byłoby uzyskać podczas pomiarów, stworzono sztuczny model wzorców dane-wyniki, odpowiadający zmiennym grubościom nawierzchni. Do stworzenia takiego zbioru danych wykorzystano standardowy model propagacji fali penetroradaru w strukturze nawierzchni.

Po procesie uczenia sieci dokonano sprawdzenia efektywności jej pracy. W tym celu wykonano 4 specjalne odcinki nawierzchni różniące się grubościami warstw betonu asfaltowego. Posłużyły one do sprawdzenia, z jaką dokładnością sieć neuronowa oszacuje grubość warstwy ścieralnej używając jako danych wyników otrzymanych z penetroradaru. Poszczególne odcinki próbne miały następujące grubości warstwy ścieralnej: 100 mm, 140 mm, 60 mm, 110 mm. Odchylenie wyników oscylowało w zakresie ± 20 mm. Największe odchylenia od

rzeczywistej grubości występują w przypadku odcinka o najcieńszej warstwie bitumicznej. Jest to spowodowane zastosowaniem określonej częstotliwości penetroradaru. Dokładność osiągniętych wyników może zostać poprawiona po zastosowaniu wyższych częstotliwości oraz dwóch oddzielnych anten.

3. Generalna konkluzja

Sieci neuronowe znalazły szerokie zastosowanie w wielu dziedzinach nauki i techniki. Dzięki takim cechom, jak zdolności do uogólniania, małej wrażliwości na błędy czy możliwości uczenia, sieci neuronowe stają się potężnym narzędziem umożliwiającym rozwiązywanie wielu zagadnień związanych z prognozowaniem, optymalizacją czy sterowaniem układów. Poważną wadą sieci neuronowych jest jednak konieczność wykorzystania dużej bazy danych, zarówno w procesie uczenia, jak i testowania. Prezentowane przykłady zastosowań inżynierii ruchu, planowania układów komunikacyjnych oraz w drogownictwie wskazują na ich efektywność.

LITERATURA

1. Korbicz J., Obuchowicz A., Uciński D.: Sztuczne sieci neuronowe, Warszawa 1994.
2. Osowski St.: Sieci neuronowe, Warszawa 1996.
3. Ivanova P., Dagarev T.: Intelligent techniques for short-term traffic intensity forecasting, Transportation Systems, Chania, Greece 1997.
4. Fusco G., Recchia R.: O-D matrix estimation and incident detection in urban areas using artificial neural networks, Transportation Systems, Chania, Greece 1997.
5. Błazejowski K., Szostakowski J.: Neuronowa metoda interpretacji wyników badań grubości warstw nawierzchni z penetroradaru.

Recenzent: Dr hab. inż. Chi Tran

Abstract

This paper presents possibility of using neural networks in short term traffic intensity forecasting, O-D matrix estimation and determining of width of road pavement. It is an attempt of presentation of neural networks in practice on various fields of road engineering.