

Jacek Oskarbski, Katarzyna Palikowska, Karol Żarski

Politechnika Gdańska, Wydział Inżynierii Lądowej i Środowiska

SYSTEMY AUTOMATYCZNEGO WYKRYWANIA ZDARZEŃ NIEPOŻĄDANYCH W MIASTACH

Rękopis dostarczono: kwiecień 2016

Streszczenie: Pierwsze systemy automatycznego wykrywania incydentów pojawiały się na amerykańskich drogach już w drugiej połowie ubiegłego wieku. Obecnie obserwujemy wiele przykładów wdrożeń metod Inteligentnych Systemów Transportu w Polsce, które także stwarzają szanse na zarządzanie zdarzeniami niebezpiecznymi i ich wykrywanie zarówno na drogach zamiejskich, jak i w sieciach ulicznych obszarów zurbanizowanych. W referacie przedstawiono przegląd metod wykrywania zdarzeń niepożądanych w obszarach miejskich. Przedstawiono ponadto metodykę opracowywania modeli, które posłużą do wykrywania zdarzeń niepożądanych na skrzyżowaniach z sygnalizacją świetlną natychmiast po wystąpieniu nietypowych zaburzeń w ruchu i wstępne wyniki badań.

Słowa kluczowe: Inteligentne systemy transportu, bezpieczeństwo ruchu, zarządzanie ruchem

1. WSTĘP

Wykrycie zagrożeń w ruchu i ostrzeżenie kierowców o ich wystąpieniu możliwe jest dzięki zastosowaniu środków i aplikacji Inteligentnych Systemów Transportu. Losowo występujące zdarzenia niepożądane na drogach (np. unieruchomienie pojazdu na skutek jego awarii lub niedyspozycji kierowcy, obiekty na drodze, awaria elementów infrastruktury drogowej oraz zdarzenia niebezpieczne – wypadek lub kolizja) ograniczają przepustowość elementów układu drogowego i powodują wzrost strat czasu oraz zwiększają prawdopodobieństwo wystąpienia zdarzeń wtórnych (kolizji lub wypadków).

Do zdarzeń niepożądanych zaliczamy [10] zachowania przed konfliktowe i konflikty ruchowe, zwane incydentami w innych rodzajach transportu (kolejowym, wodnym i lotniczym) oraz zdarzenia niebezpieczne, które w zależności od skutków dzieli się na zdarzenia niebezpieczne, tylko ze stratami materialnymi (kolizje drogowe) i zdarzenia niebezpieczne ze stratami osobowymi (wypadki drogowe z ofiarami rannymi, wypadki drogowe z ofiarami śmiertelnymi oraz wypadki drogowe z wieloma ofiarami śmiertelnymi tj. katastrofy drogowe).

Wczesne wykrycie zdarzenia przyczynia się do skrócenia czasu jego trwania oraz skrócenia czasu potrzebnego na udzielenie pomocy poszkodowanym, czego wynikiem jest

zmniejszenie ciężkości wypadku, zminimalizowanie okresu ekspozycji na ryzyko wystąpienia zdarzeń wtórnych, jak również zminimalizowanie strat czasu podróżujących [2], [22]. Wskazuje się na korzyści wynikające z redukcji zdarzeń seryjnych i wtórnych (do 29%), redukcję czasu pracy kierowców, redukcję zużycia paliwa i emisji spalin [3], [29]. Na podstawie wyników badań europejskich szacuje się, że stosowanie środków telematiki transportu może zmniejszyć czas reakcji i interwencji służb ratowniczych nawet o 30% a wykorzystanie wywołań alarmowych, generowanych automatycznie przez systemy zastosowane w pojazdach zwiększa prawdopodobieństwo przeżycia ofiary wypadku o 15% [6], [20]. W opracowaniach [9], [29] wskazano korzyści z wykorzystania środków Inteligentnych Systemów Transportu, jakimi są redukcja zdarzeń wtórnych (15 – 38%), redukcja wypadków rodzaju „najechanie na tył pojazdu” (4-30%) oraz redukcja ciężkości zdarzeń wtórnych (21-43%). Jednym z najważniejszych przedsięwzięć, które pozwolą na znaczne zmniejszenie skutków wypadków będzie wprowadzenie ogólnoeuropejskiego systemu szybkiego powiadomienia o wypadkach drogowych – eCall [20]. Wdrożenie systemu eCall niewątpliwie przyczyni się do szybszego wykrycia zdarzeń niebezpiecznych, jednakże szybkiego wykrycia wymagają również inne incydenty, które mogą skutkować zdarzeniami wtórnymi [21].

Rozmowy z przedstawicielami Straży Pożarnej wskazały korzyści, których mogą dostarczyć systemy wykrywania zdarzeń ze względu na błędy w bieżącym powiadomianiu przez świadków lub osób biorących udział w zdarzeniu oraz brak zdolności do oceny wagi incydentu. Obserwacje wykazały wpływ zdarzeń na długoterminowe zakłócenia w ruchu, które mogą być ograniczone przez wprowadzenie odpowiednich strategii zarządzania ruchem i informowania kierowców. Bez opracowania narzędzi ostrzegających wykwalifikowanych operatorów o możliwości wystąpienia zdarzenia drogowego zaangażowanie Centrum Zarządzania Ruchem w zakresie wykrywania i zgłaszania incydentów oraz podejmowania natychmiastowych działań w celu przywrócenia normalnych warunków ruchu będzie ograniczone. Wprowadzenie powyższych ulepszeń będzie możliwe po przeprowadzaniu wielu rozmów, opracowaniu procedur i podpisaniu odpowiednich umów o współpracy. Dialog pomiędzy Centrum Zarządzania Ruchem w Gdyni i Strażą Pożarną został zainicjowany w ramach projektu CIVITAS DYN@MO. W ramach projektu prowadzone są również badania, których pierwsze wyniki przedstawiono w niniejszym referacie.

2. ALGORYTMY WYKRYWANIA ZDARZEŃ

W porównaniu do ruchu na autostradach, parametry i stan ruchu na arteriach miejskich zmienia się bardziej dynamicznie i podlega większym zakłóceniom ze względu na wpływ sygnalizacji świetlnej, przejść dla pieszych (legalnych lub nielegalnych), manewrowania podczas parkowania, przystanków transportu zbiorowego, regularnych lub losowych kolejek na wlotach skrzyżowań, występowaniem wjazdów, robót drogowych, nielegalnych zatrzymań, blokowania skrzyżowań itp. Ze względu na powyższe czynniki, algorytmy wykorzystywane na autostradach zwykle nie są skuteczne w miejskich warunkach i są mniej skomplikowane. Poniżej opisano dotychczas wdrożone lub testowane propozycje algorytmów wykrywania zdarzeń na arteriach miejskich, które zestawiono w Tablicy 1.



Tablica 1

Przykłady wykorzystania algorytmów wykrywania zdarzeń w miastach

Algorytm	Wykorzystane dane	Zasada działania	Zastosowanie
Pattern Matching [28], [7], [23]	Zmienność natężenia ruchu i zajętości stacji pomiarowych wlotowych i wylotowych	Śledzenie zmienności parametrów ruchu oraz określenia odpowiednich wzorców ruchu w celu odróżnienia zdarzeń niepożądanych od warunków ruchu bez zdarzeń (z uwzględnieniem awarii systemu sterowania)	Wykrycie zdarzenia, blokada pasa, wlotu
Kalman Filtering [17]	Zagregowane natężenia ruchu i prędkości	Oszacowanie historycznych parametrów ruchu i porównanie ich z pomierzonymi wartościami w celu wykrycia zdarzenia	Wykrycie zdarzenia niepożądanego
Analiza dyskryminacyjna [24]	Zajętość detektora (stacja pomiaru) i czas przejazdu (pojazd próbny)	Zakłócenia przepływu ruchu podczas zdarzenia – wzrost zajętości detektora i wzrost czasu przejazdu, a także zmniejszenie natężenia ruchu na rozpatrywanym i na sąsiednim odcinku	Wykrycie zdarzenia niepożądanego
Modułowy neuronowy [13]	Dane z badań terenowych i symulacyjnych	Testowanie modułowego algorytmu opartego na sieciach neuronowych i porównaniu go do modelu MLF, algorytmu Bayesian, oraz analizy dyskryminacyjnej	Wykrycie zdarzenia, blokowania pasa, awarii detektora
Fuzzy Logic [18]	Natężenie ruchu, długość kolejki, zajętość detektora i prędkości	Moduł wnioskowania normalności, moduł wnioskowania lokalizacji zdarzenia, moduł oceny stopnia ciężkości zdarzenia i moduł wnioskowania zakończenia zdarzenia	Wykrywanie zdarzeń na skrzyżowaniach z sygnalizacją
TSC ar [30]	Natężenie ruchu, zajętość pasa – testowany danymi z symulacji	Sieci bayesowskie zostały skonstruowane do przechowywania ogólnej specjalistycznej wiedzy o ruchu drogowym i przeprowadzenia uniwersalnego wykrywania zdarzeń	Wykrywanie zdarzeń zarówno dla autostrad i dróg miejskich
Sequential probability ratio tests [26]	Natężenie ruchu, zajętość i długości kolejek	Identyfikacja objawu, przetwarzanie sygnału wykorzystywane do surowych danych o ruchu i prognozowanie w czasie rzeczywistym parametrów związanych ze zdarzeniem, rozpoznanie wzorców w procesie decyzyjnym	Rozpoznanie zdarzeń na pasach ruchu
INGRID [25]	Zmienność natężenia ruchu i zajętości stacji pomiarowych	Porównanie obecnej sytuacji ruchu z oczekiwaną na podstawie historycznych danych referencyjnych	Wykrywanie zdarzeń
MID – MOTION [15]	Natężenie ruchu, stopień zajętości, stopień nasycenia	Na podstawie danych o bieżącym programie sygnalizacji oblicza stopień nasycenia dla grup sygnałowych. Następnie aktualne natężenie porównywane jest z przepustowością danego skrzyżowania	Wykrywanie zdarzeń

System wykrywania zdarzeń niebezpiecznych do ich automatycznego wykrywania, rejestracji i raportowania na skrzyżowaniach z wykorzystaniem algorytmu śledzenia pojazdów został przedstawiony w [14]. Najtrudniejszym problemem związanym ze śledzeniem pojazdów jest efekt okluzji. W celu rozwiązania tego problemu algorytm, nawiązał do czasoprzestrzennego pola losowego Markowa (MRF) dla obrazów ruchu na skrzyżowaniach, a następnie systemu rozpoznawania zdarzeń opartego na modelu ukrytym Markowa (HMM) [11].

Plany sygnalizacji są istotnym czynnikiem wpływającym na czas wykrycia zdarzeń. Większość algorytmów miejskich zostało opracowanych do wykrywania zdarzeń na odcinkach arterii między skrzyżowaniami, niektóre umożliwiają wykrywanie na skrzyżowaniach.



Większość wypadków drogowych występuje na lub w pobliżu skrzyżowań, gdzie straty czasu są najbardziej poważne i mogą wywołać impas lokalny lub w większym obszarze sieci ulicznej.

3. OPIS PRZYPADKU

W niniejszym artykule wykorzystano dane pomiarowe pochodzące z pętli indukcyjnych skrzyżowania ulic Morska-Owsiana w Gdyni.

Dane pomiarowe używane są do wyznaczenia parametrów potoku ruchu. Wykrywanie zdarzeń na skrzyżowaniu na podstawie tych parametrów jest zadaniem trudnym ze względu na fakt, iż powtarzające się spowolnienia ruchu na skutek zatłoczenia powodują zmiany parametrów ruchu podobne do zmian występujących podczas zdarzeń niepożądanych [1][12].

W bazie danych systemu TRISTAR rejestrowane są następujące dane: dokładny czas wzbudzenia pętli (związany z zarejestrowaniem faktu pojawienia się pojazdu), prędkość pojazdu V , jego długość L , czas spędzony nad punktem kontrolnym T oraz odległość do pojazdu poprzedzającego D . Oprócz wzbudzeń rejestrowanych przez pętle indukcyjne wykorzystano dane dotyczące zmian sygnalizacji na skrzyżowaniu, mające wpływ na specyfikę potoków ruchu w obrębie skrzyżowania. Dane obejmują dokładny czas zmiany stanu sygnalizacji dla grupy o zarejestrowanym numerze.

Wstępne przetwarzanie danych oparto na uwzględnieniu cykli zmian sygnalizacji poprzez agregację danych związanych ze wzbudzeniami pętli w ramach pojedynczego cyklu o zmiennym czasie trwania. W Tablicy 2 przedstawiono format zagregowanych danych opisujący pojedynczy cykl (ok. 600-700 w ciągu doby), wyznaczonych oddzielnie w odniesieniu do każdego punktu kontrolnego PK.

Tablica 2

Format danych zagregowanych w ramach cykli

Lp	Start_UT C	Czas trwania cy- klu [s]	Pora	PK 0				PK 1		...
				Ile	V	T	D	Ile	...	
1	05:00:45	115	300	17,74	30,85	29,79	34,05	20,34		
2	05:02:40	108	302	10	37,72	13,72	60,44	15,55		
...										

Zastosowany sposób agregacji danych polegający na wyznaczaniu średnich wartości liczby pojazdów, średniej prędkości pojazdów czy średniej zajętości pasa ruchu w przedziale czasu o ustalonej długości był często opisywany w literaturze [1][12][19]. W niniejszym artykule stosowane przy agregacji danych przedziały czasu posiadają zmienną długość i odpowiadają długościom cykli zmian sygnalizacji na skrzyżowaniu.

Dane uzyskane w wyniku zastosowanej agregacji (Tab. 2) można traktować w różny sposób, w zależności od wymagań docelowego modelu. Model może być zasilany danymi z wybranych kolumn (każda kolumna reprezentuje szereg czasowy) lub wielowymiarowymi danymi z wierszy (wiersz reprezentuje cykl zmian sygnalizacji).

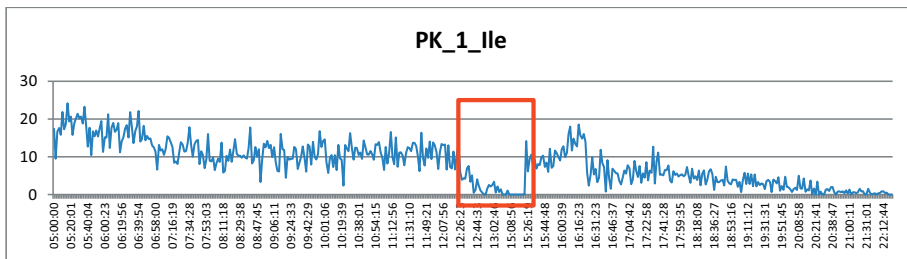


Zasadnicze podejście zakłada, że dane te tworzą odrębne dla każdego punktu kontrolnego szeregi czasowe: $PK_n Ile(t)$, $PK_n V(t)$, $PK_n T(t)$, $PK_n D(t)$, gdzie $t=t_1, t_2, \dots, t_n$ i oznacza czas rozpoczęcia kolejnego cyklu sygnalizacji (n – numer punktu kontrolnego).

Alternatywne podejście, charakterystyczne dla analizy wielowymiarowej, traktuje pojedynczy cykl zmian sygnalizacji (wiersz w Tab. 3) jako punkt w przestrzeni wielowymiarowej o współrzędnych: $PK_0 Ile$, $PK_0 V$, $PK_0 T$, $PK_0 D$, $PK_1 Ile$, $PK_1 V$, ... , $PK_n T$, $PK_n D$ zawartych w kolejnych kolumnach Tablicy 2.

Pełna ocena efektywności zastosowanego sposobu przetworzenia danych może zostać przeprowadzona dopiero w końcowej fazie, na etapie walidacji proponowanego modelu. Istnieje jednak możliwość przeprowadzenia wstępnej oceny na podstawie odpowiedzi na pytanie czy istnieje zależność pomiędzy zagregowanymi danymi (Tab. 2), reprezentującymi parametry potoków ruchu w dniu testowym, a rejestrem zdarzeń z tego dnia. Ocena zostanie dokonana z zastosowaniem dwóch różnych perspektyw spojrzenia na zagregowane dane.

Na Rys. 1 przedstawiono szereg czasowy $PK_1 Ile$ reprezentujący średnią liczbę pojazdów / 60 s zarejestrowanych w punkcie kontrolnym 1 w kolejnych cyklach zmian sygnalizacji w dniu 2015-05-05 na skrzyżowaniu ulic Morska-Owsiana w Gdyni. W tym dniu w godzinach 12:24:24-15:21:41 wystąpił incydent. Na Rys. 1 przedział czasowy obejmujący godzinny wystąpienia incydentu oznaczono prostokątną ramką. Incydentowi towarzyszył gwałtowny spadek średniej liczby pojazdów, związany z zatrzymaniem ruchu na skrzyżowaniu.




Rys. 1. Szereg czasowy $PK_1 Ile$ (średnia liczba pojazdów / 60 s) w dniu 2015-05-05

„Widoczność” incydentu stanowi dobrą prognozę możliwości zastosowania modeli opartych na analizie szeregów czasowych $PK_n Ile$. Analogiczny obraz uzyskano dla szeregu $PK_n V$. Na Rys. 1 cykle objęte incydem wyróżniają się na tle cykli odpowiadających ruchowi normalnemu z jednym wyjątkiem. Ten wyjątek stanowią wybrane cykle nocne, w których ruch zamiera z przyczyn niezwiązanych z wystąpieniem incydentu. Podobieństwo cykli z incydem do cykli nocnych bez incydentu może stawiać wyzwanie przed kandydującymi metodami automatycznego wykrywania incydentów. Wyzwanie to polega na konieczności wygaszania fałszywych alarmów, szczególnie w metodach dedykowanych do stosowania w trybie on-line.

Efektywność wykorzystania modelu opartego na szeregach średniej liczby pojazdów i średniej prędkości w modelu stosowanym offline została potwierdzona w pracy [1]. W modelach przedstawionych w pracach [12] i [19] dodatkowo uwzględniono szereg reprezentujący zajętość pasa ruchu.

Przyjmując, że pojedynczy cykl jest punktem w przestrzeni 32-wymiarowej (16 punktów kontrolnych \times 2 współrzędne PK_n_Ile i PK_n_V) przeprowadzono analizę składowych głównych [16] na danych z dnia 2015-05-05 z incydem, poddanych standaryzacji. Wykorzystano funkcję `prcomp` programu R www.r-project.org. Na Rys. 2 przedstawiono wynik rzutowania punktów z przestrzeni 32-wymiarowej (reprezentujących cykle z dnia 2015-05-05) na płaszczyznę utworzoną przez pierwsze dwie składowe główne PC1 i PC2.




Rys. 2. Wynik rzutowania 496 punktów będących obrazami cykli z dnia 2015-05-05 na płaszczyznę utworzoną przez dwie pierwsze składowe główne PC1 i PC2

Na rys. 2 liczby oznaczają numery porządkowe cykli w obrębie dnia. Cykle o numerach 239-277 obejmują godziny wystąpienia incydentu. Na Rys. 2 są wyraźnie widoczne, tworząc wyraźnie oddzielony klaster i różniąc się zarówno od cykli nocnych jak i cykli reprezentujących ruch normalny. Uzyskany wynik rzutowania dowodzi istnienia podobieństwa cykli z incydem oraz potencjalnej możliwości ich odróżnienia zarówno od cykli z ruchem normalnym jak i cykli nocnych.

Uzyskane wyniki (rys. 1 i 2) pozwalają na zakończenie pozytywnym wynikiem wstępnej oceny efektywności agregacji i możliwości skutecznego zastosowania metod klasyfikujących.

3.1. ARCHITEKTURA KLASYFIKATORA

Przyjęto modułową architekturę klasyfikatora, przedstawioną w pracy [13], która umożliwia analizę porównawczą zastosowanych modeli oraz ułatwia przeprowadzenie procesu kalibracji modeli wymagających określenia wartości progowych (rys. 3). Odpowiedzi każdego z modeli są wyznaczane odrębnie w odniesieniu do każdego cyklu, analogicznie do systemu opisanego w pracy [1]. Odpowiedź modelu $S_i \in \langle 0,1 \rangle$ jest ciągła i jest interpretowana jako miara prawdopodobieństwa wystąpienia incydentu podczas badanego cyklu. Moduł decyzyjny generuje odpowiedź końcową z wykorzystaniem odpowiedzi cząstkowych uzyskanych z poszczególnych modeli [13].



Rys. 3. Architektura Klasyfikatora

W niniejszym artykule przedstawiono 2 modele wchodzące w skład Klasyfikatora przedstawionego na rys. 3: model FiltrLp oparty na zastosowaniu filtra dolnoprzepustowego do dekompozycji szeregu czasowego oraz model ANN oparty na zastosowaniu sztucznych sieci neuronowych.


Podstawą modelu FiltrLp jest dekompozycja szeregu czasowego PK_n_{Ile} lub PK_n_V na 2 składowe, z których składowa otrzymana w wyniku zastosowania filtra dolnoprzepustowego jest traktowana jako trend. Model opiera się na sygnalizowaniu różnicy bieżącego trendu i trendu „normalnego” tj. trendu w dniu podobnym do badanego [27], o którym wiadomo, że był wolny od incydentów.

Model oparty na sztucznych sieciach neuronowych został oparty na sieci o 17 wejściach skalowanych na przedział $\langle 0,1 \rangle$, 2 warstwach ukrytych zawierających po 100 neuronów i 2 wyjściach reprezentujących kierunek do Gdyni i do Rumii. Proces uczenia sieci przeprowadzono w oparciu o dane zagregowane w obrębie cykli i rejestr zdarzeń z wykorzystaniem Toolboxa ANN [8] w programie SciLab. Rejestr zdarzeń powstał w oparciu o ręczną analizę danych historycznych dokonaną na podstawie nagrań wideo, raportów drogowych oraz analizy parametrów potoków ruchu. Oprócz incydentów odnotowano również zdarzenia określone jako blokowanie lub kolejka. Rozszerzono tym samym zakres rozpoznawanych wzorców ruchu w stosunku zakresów przedstawionych w pracach [4], [5] czy [19].

3.2 WYNIKI

Działanie modeli przetestowano na danych z dnia 2015-06-04, w którym odnotowano incydent w postaci wstrzymania ruchu na skrzyżowaniu. Na Rys. 4 przedstawiono odpowiedzi modelu FiltrLP (kolor niebieski ze znacznikiem x) i ANN (kolor czerwony). Oprócz prawidłowo rozpoznanego incydentu modeli FiltrLP zgłosił fałszywe alarmy ok. godziny 15:13 i wieczorem po godz. 19.00.

Modułarna architektura Klasyfikatora (rys. 4) pozwala na uwzględnienie odpowiedzi modeli o różnych właściwościach, co ułatwia uniknięcie generowania fałszywych alarmów przez Klasyfikator.



Rys. 4. Odpowiedź modeli FiltrLP i ANN na dane z dnia 2015-06-04

4. WNIOSKI

Przedstawiony w artykule opis przypadku objął dane z godzin 05:00-23:00. W modelu FiltrLP odnotowano wystąpienie fałszywych alarmów w godzinach wieczornych, co związane jest ze znikomym natężeniem ruchu charakteryzującym cykle nocne. W toku dalszych prac należy uwzględnić dane całodobowe oraz podjąć próby rozróżnienia cykli nocnych od cykli ze zdarzeniem, co na podstawie dokonanej w artykule oceny efektywności zastosowanego sposobu agregacji danych wydaje się być możliwe.

W opisanych modelach zastosowano dane dotyczące średniej liczby pojazdów i ich średniej prędkości. Rozróżnienie cykli nocnych od cykli z incydem oraz poprawa efektywności modeli w zakresie sygnalizowania wzorców ruchu typu blokowanie czy kolejka mogą być możliwe po rozszerzeniu danych o parametr związany z zajętością pasa ruchu, który może zostać wyznaczony na podstawie parametru T (czasu spędzonego przez pojazd nad punktem kontrolnym). Parametr ten wydaje się być pozytywny z punktu widzenia uniknięcia fałszywych alarmów przy zerowym natężeniu ruchu (wolny pas i brak wzbudzeń pętli) w odróżnieniu od zdarzenia (zajęty pas i brak wzbudzeń pętli).

Obiecującym elementem zaproponowanego podejścia do analizy parametrów ruchu jest modułarna struktura klasyfikatora, który można uzupełniać o nowe modele. Prace badawcze

zmierzają do takiego rozwoju klasyfikatora, aby określać na bieżąco przydatność poszczególnych algorytmów i wybierać konkretny model dla określonej pory dnia, tygodnia, roku. Niezbędne w dalszych pracach jest umożliwienie wykorzystania danych w czasie rzeczywistym bez konieczności ich oddzielnego konwertowania. Powyższe wymaga ingerencji w mechanizm działania systemu TRISTAR.

Bibliografia

1. Ahmed F., Hawas Y.: A Threshold-Based Real Time Incident Detection System for Urban Traffic Networks, *Procedia-Social and Behavioral Science*, 48 (2012) 1713-1722, Transport Research Arena – Europe 2012.
2. Button K. J., Hensher D. A. Schintler L.: *Handbook of Transport Systems and Traffic Control*, Pergamon 2001.
3. Chang, G. L., Rochon S.: Performance Evaluation and Benefit Analysis for CHART in Year 2007. Final report, 2007. <http://chartinput.umd.edu/reports/chart2007final.pdf>
4. Dia H., Rose G.: Development and evaluation of neural network freeway incident detection models using field data, *Transportation Research Part C*, 5 (5) 1997, 313-331.
5. Dia H., Thomas K.: Development and evaluation of arterial incident detection models using fusion of simulated probe vehicle and loop detector data, *Information Fusion*, 12 (2011) 20-27.
6. ERTICO: Expected Benefits of ITS, 4th World Congress of ITS, Berlin, Germany, 1997.
7. Han L. D., May A. D.: Automatic detection of traffic operational problems on urban arterials, Research Report UCB-ITS-RR-89-15, Institute of Transportation Studies, Univ. of California, Berkeley, CA, 1989.
8. Hristev R., Cornet A.: http://atoms.scilab.org/toolboxes/ANN_Toolbox/0.4.2.5
9. INSTITUTE OF TRANSPORTATION ENGINEERS: 1996 ITS Tour Report: Eastern North America and 1996 ITS World Congress: Volume I. 1997
10. Jamroz K., Kadziński A., Szymanek A., Chruzik K., Gucma L., Skorupski J.: Integracja metod zarządzania ryzykiem w transporcie. Rozdz. 7 w pracy zbiorowej pod red. R. Krystka pt.: Zintegrowany System Bezpieczeństwa Transportu, tom 2: Uwarunkowania rozwoju integracji systemów bezpieczeństwa transportu. WKŁ Warszawa 2009.
11. Kamijo S., Matsushita Y., Ikeuchi K., Sakauchi M.: Traffic monitoring and accident detection at intersections, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 1, No. 2, 2000, pp. 108-118.
12. Karim A., Adeli H.: Incident detection algorithm using wavelet energy representation of traffic patterns, *Journal of Transportation Engineering*, ASCE, 128 (3) 2002, 232-242.
13. Khan S., Ritchie S.: Statistical and neural classifiers to detect traffic operational problems on urban arterials, *Transportation Research Part C*, 6 (1998) 291-314.
14. Ki Y. K.: Accident detection system using Image Processing and MDR, *IJCSNS International Journal of Computer Science and Network Security*, Vol.7 No.3, 2007, pp. 35-39.
15. Kruse G., Tannert R., Hasberg P.: Incident detection by MOTION for strategic control in the traffic management system StadtinfoKöln, 7th World Congress on ITS, Turin, Italy. CD-Rom, 2000.
16. Krzyśko M., Wołyński W., Górecki T., Skorzybut M.: Systemy uczące się. Rozpoznawanie wzorców, analiza skupień i redukcja wymiarowości, WNT, Warszawa 2008.
17. Lee J. T., Taylor W. C.: Application of a dynamic model for arterial street incident detection, *ITS Journal*, Vol. 5, No. 1, 1999, pp. 53-70.
18. Lee S., Krammes R. A., Yen J.: Fuzzy-logic-based incident detection for signalized diamond interchanges, *Transportation Research Part C*, Vol. 6, No. 3, 1998, pp. 359-377.
19. Lu J., Chen S., Wang W., Zuylen H.: A hybrid model of partial least squares and neural network for traffic incident detection, *Expert Systems with Application*, 39 (2012) 4775-4784.
20. McDonald M., Keller H., Klijnhout J., Mauro V., Hall R., Spence A., Hecht C., Fakler O.: *Intelligent Transport Systems in Europe. Opportunities for Future Research*. World Scientific, 2006.
21. Oskarbski J., Jamroz K., Zawisza M., Żarski K.: Systemy wykrywania zdarzeń niepożądanych na autostradach i drogach ekspresowych. *Drogownictwo* nr 4-5 (2015), 150-154.
22. Oskarbski J.: Automatyzacja zarządzania zdarzeniami drogowymi. *Drogownictwo* 4 (2012), 153-156.



23. Rau L., K., Tarko A. P.: A congestion-oriented approach to detect incidents and to estimate capacities on signalized streets," Preprint CD-ROM, the 79th TRB Annual Meeting, Transportation Research Board, National Research Council, Washington D.C., January 2000.
24. Sethi V., Bhandari N., Koppelman F. S., Schofer J. L.: Arterial incident detection using fixed detector and probe vehicle data, Transportation Research Part C, Vol. 3, No. 2, 1995, pp. 99-112.
25. Sharma S., Gidde M. R.: Estimated outcome of application of Split Cycle Offset Optimization Technique (SCOOT) & Reduction of frequency of buses, International J. of Engineering Research & Management Technology, Vol. 1, Issue-5, 2014, pp. 82-90.
26. Sheu J. B., Ritchie S. G.: A new methodology for incident detection and characterization on surface streets, Transportation Research Part C, Vol. 6, No. 3, 1998, pp. 315-335.
27. Tang J., Wang Y., Wang H., Zhang S., Liu F.: Dynamic analysis of traffic time series at different temporal scales: A complex networks approach, Physica A, 405 (2014), 303-315.
28. Thancanamootoo S., Bell M. G. H.: Automatic detection of traffic incidents on a signal-controlled road network, Research Report No. 76, Transport Operations Research Group, University of Newcastle upon Tyne, UK, 1988.
29. TRANSPORTATION RESEARCH BOARD: Analytical procedures for determining the Impacts of Reliability Mitigation Strategies, SHRP2 Reliability Research, Report S2-LO3-RR-1, 2013
30. Zhang K., Taylor M. A. P.: Towards transferable incident detection algorithms, Journal of the Eastern Asia Society for Transportation Studies, Vol. 6, 2005, pp. 2263 – 2274.

AUTOMATIC INCIDENT DETECTION SYSTEMS IN URBAN AREAS

Summary: The first automatic incident detection systems appeared on American roads in the second half of the last century. We can find many examples of implementations of methods of Intelligent Transport Systems in Poland, which also offer opportunities to manage incidents and their detection on both rural roads and street networks in urban areas. The paper presents an overview of methods for detecting incidents in urban areas. The paper presents also the methodology for developing models that will be used for the detection of incidents at intersections with traffic lights immediately after the occurrence of unusual disturbances in traffic and preliminary results of researches.

Keywords: Intelligent Transportation Systems, traffic safety, traffic management

Praca naukowa finansowana jest ze środków finansowych na naukę w latach 2013 – 2016 przyznanych na realizację projektu międzynarodowego współfinansowanego w ramach unijnego projektu CIVITAS DYN@MO.

