



**POLITECHNIKA
GDAŃSKA**

WYDZIAŁ INŻYNIERII LĄDOWEJ
I ŚRODOWISKA



Imię i nazwisko studenta: *Krzystian Mowiński*
Nr albumu: 133031
Imię i nazwisko studenta: *Tomasz Marcinkowski*
Nr albumu: 133029
Studia drugiego stopnia

Forma studiów: stacjonarne

Kierunek studiów: Transport

Specjalność/profil: Systemy Transportowe

PRACA DYPLOMOWA MAGISTERSKA

Tytuł pracy w języku polskim: **Wykrywanie incydentów w miejskiej sieci ulicznej z wykorzystaniem sieci neuronowych**

Tytuł pracy w języku angielskim: **Detection of incidents in the urban network using neural networks**

Potwierdzenie przyjęcia pracy	
Opiekun pracy	Kierownik Katedry/Zakładu
<i>podpis</i>	<i>Podpis</i>

Data oddania pracy do dziekanatu:



**POLITECHNIKA
GDAŃSKA**

WYDZIAŁ INŻYNIERII LĄDOWEJ
I ŚRODOWISKA



OŚWIADCZENIE

Imię i nazwisko: Tomasz Marcinkowski
Data i miejsce urodzenia: 01.12.1991, Wąbrzeźno
Nr albumu: 133029
Wydział: Wydział Inżynierii Lądowej i Środowiska
Kierunek: transport
Poziom studiów: II stopnia
Forma studiów: stacjonarne

Ja, niżej podpisany(a), wyrażam zgodę/~~nie wyrażam zgody*~~ na korzystanie z mojej pracy dyplomowej zatytułowanej: **Wykrywanie incydentów w miejskiej sieci ulicznej z wykorzystaniem sieci neuronowych** do celów naukowych lub dydaktycznych.¹

Gdańsk, dnia

.....
podpis studenta

Świadomy(a) odpowiedzialności karnej z tytułu naruszenia przepisów ustawy z dnia 4 lutego 1994 r. o prawie autorskim i prawach pokrewnych (Dz. U. z 2006 r., nr 90, poz. 631) i konsekwencji dyscyplinarnych określonych w ustawie Prawo o szkolnictwie wyższym (Dz. U. z 2012 r., poz. 572 z późn. zm.),² a także odpowiedzialności cywilno-prawnej oświadczam, że przedkładana praca dyplomowa została opracowana przeze mnie samodzielnie.

Niniejsza(y) praca dyplomowa nie była wcześniej podstawą żadnej innej urzędowej procedury związanej z nadaniem tytułu zawodowego.

Wszystkie informacje umieszczone w ww. pracy dyplomowej, uzyskane ze źródeł pisanych i elektronicznych, zostały udokumentowane w wykazie literatury odpowiednimi odnośnikami zgodnie z art. 34 ustawy o prawie autorskim i prawach pokrewnych.

Potwierdzam zgodność niniejszej wersji pracy dyplomowej z załączoną wersją elektroniczną.

Gdańsk, dnia

.....
podpis studenta

Upoważniam Politechnikę Gdańską do umieszczenia ww. pracy dyplomowej w wersji elektronicznej w otwartym, cyfrowym repozytorium instytucjonalnym Politechniki Gdańskiej oraz poddawania jej procesom weryfikacji i ochrony przed przywłaszczeniem jej autorstwa.

Gdańsk, dnia

.....
podpis studenta

*) niepotrzebne skreślić

¹ Zarządzenie Rektora Politechniki Gdańskiej nr 34/2009 z 9 listopada 2009 r., załącznik nr 8 do instrukcji archiwalnej PG.

² Ustawa z dnia 27 lipca 2005 r. Prawo o szkolnictwie wyższym:

Art. 214 ustęp 4. W razie podejrzenia popełnienia przez studenta czynu podlegającego na przypisaniu sobie autorstwa istotnego fragmentu lub innych elementów cudzego utworu rektor niezwłocznie poleca przeprowadzenie postępowania wyjaśniającego.

Art. 214 ustęp 6. Jeżeli w wyniku postępowania wyjaśniającego zebrany materiał potwierdza popełnienie czynu, o którym mowa w ust. 4, rektor wstrzymuje postępowanie o nadanie tytułu zawodowego do czasu wydania orzeczenia przez komisję dyscyplinarną oraz składa zawiadomienie o popełnieniu przestępstwa.



**POLITECHNIKA
GDAŃSKA**

WYDZIAŁ INŻYNIERII LĄDOWEJ
I ŚRODOWISKA



OŚWIADCZENIE

Imię i nazwisko: Krystian Mowiński
Data i miejsce urodzenia: 06.01.1991, Starogard Gdański
Nr albumu: 133031
Wydział: Wydział Inżynierii Lądowej i Środowiska
Kierunek: transport
Poziom studiów: II stopnia
Forma studiów: stacjonarne

Ja, niżej podpisany(a), wyrażam zgodę/~~nie wyrażam zgody*~~ na korzystanie z mojej pracy dyplomowej zatytułowanej: **..Wykrywanie incydentów w miejskiej sieci ulicznej z wykorzystaniem sieci neuronowych..** do celów naukowych lub dydaktycznych.¹

Gdańsk, dnia**23.09.2015r.**.....
.....
podpis studenta

Świadomy(a) odpowiedzialności karnej z tytułu naruszenia przepisów ustawy z dnia 4 lutego 1994 r. o prawie autorskim i prawach pokrewnych (Dz. U. z 2006 r., nr 90, poz. 631) i konsekwencji dyscyplinarnych określonych w ustawie Prawo o szkolnictwie wyższym (Dz. U. z 2012 r., poz. 572 z późn. zm.),² a także odpowiedzialności cywilno-prawnej oświadczam, że przedkładana praca dyplomowa została opracowana przeze mnie samodzielnie.

Niniejsza(y) praca dyplomowa nie była wcześniej podstawą żadnej innej urzędowej procedury związanej z nadaniem tytułu zawodowego.

Wszystkie informacje umieszczone w ww. pracy dyplomowej, uzyskane ze źródeł pisanych i elektronicznych, zostały udokumentowane w wykazie literatury odpowiednimi odnośnikami zgodnie z art. 34 ustawy o prawie autorskim i prawach pokrewnych.

Potwierdzam zgodność niniejszej wersji pracy dyplomowej z załączoną wersją elektroniczną.

Gdańsk, dnia **23.09.2015r.**.....
.....
podpis studenta

Upoważniam Politechnikę Gdańską do umieszczenia ww. pracy dyplomowej w wersji elektronicznej w otwartym, cyfrowym repozytorium instytucjonalnym Politechniki Gdańskiej oraz poddawania jej procesom weryfikacji i ochrony przed przywłaszczeniem jej autorstwa.

Gdańsk, dnia **23.09.2015r.**.....
.....
podpis studenta

*) niepotrzebne skreślić

¹ Zarządzenie Rektora Politechniki Gdańskiej nr 34/2009 z 9 listopada 2009 r., załącznik nr 8 do instrukcji archiwalnej PG.

² Ustawa z dnia 27 lipca 2005 r. Prawo o szkolnictwie wyższym:

Art. 214 ustęp 4. W razie podejrzenia popełnienia przez studenta czynu polegającego na przypisaniu sobie autorstwa istotnego fragmentu lub innych elementów cudzego utworu rektor niezwłocznie poleca przeprowadzenie postępowania wyjaśniającego.

Art. 214 ustęp 6. Jeżeli w wyniku postępowania wyjaśniającego zebrany materiał potwierdza popełnienie czynu, o którym mowa w ust. 4, rektor wstrzymuje postępowanie o nadanie tytułu zawodowego do czasu wydania orzeczenia przez komisję dyscyplinarną oraz składa zawiadomienie o popełnieniu przestępstwa.

STRESZCZENIE

W związku z wprowadzeniem na terenie miasta Gdynia systemu TRISTAR zdecydowano się przeprowadzić wstępne badania określające skuteczność użycia sieci neuronowych w wykrywaniu incydentów na skrzyżowaniach objętych działaniem systemu. Ewentualne wyniki i wnioski będą cennym materiałem w procesie decyzyjnym wprowadzenia efektywnego modułu wykrywania incydentów będącego częścią systemu TRISTAR.

W niniejszej pracy zaprezentowano zagadnienia związane z wykrywaniem incydentów w miejskiej sieci ulicznej z wykorzystaniem sztucznych sieci neuronowych oraz zaproponowano ewentualne rozwiązania w postaci algorytmów wykorzystujących możliwości sztucznych sieci neuronowych. W pierwszej części omówiono podstawowe wiadomości wprowadzające do opracowywanej tematyki, czyli m.in.: czym jest incydent oraz jaką rolę odgrywają ITS w procesach wykrywania (opracowanie T. Marcinkowski i K. Mowiński). Następnie przybliżono zasadę działania sztucznych sieci neuronowych i omówiono ich strukturę. Przedstawiono również sposób przetwarzania danych. Opisano najpopularniejsze obecnie sposoby wykrywania zdarzeń w sieciach drogowym oraz szerzej opracowano wybrane podejścia do problemu wykrywania z wykorzystaniem sieci neuronowych. W drugiej części pracy autorzy zaprezentowali zindywidualizowane podejścia do problemu wykrywania incydentów na dwóch wybranych skrzyżowaniach w Gdyni – ul. Morska/Owsiana (K. Mowiński) oraz ul. 10 Lutego/Świętojańska (T. Marcinkowski). Opisano metodologię analizy: sposób pobrania i wykorzystania danych, dokładny opis i analizę wykorzystanych do opracowania algorytmu incydentów. W środowisku SCILAB stworzono skrypty zbiorów uczących oraz przetestowano ich możliwości. Po zaprezentowaniu i porównaniu wyników obojga autorów podsumowano osiągnięcia i wyciągnięto określone wnioski.

Słowa kluczowe:

Inżynieria lądowa: inżynieria transportu; algorytm wykrywania incydentów, sieci neuronowe, inteligentne systemy transportu, bezpieczeństwo ruchu.

ABSTRACT

Following the introduction of TRISTAR system in the city of Gdynia, it was decided to carry out preliminary studies to determine the efficacy of using neural networks to detect incidents at intersections. Any results and conclusions will be a valuable material in the decision to introduce an effective incident detection module which will be the part of the TRISTAR system.

This paper presents issues relating to the detection of incidents in the urban network using artificial neural networks and proposes possible solutions in the form of algorithms exploring the possibilities of artificial neural networks. The first part presents basic information as an introduction of developed thesis, such as: what is a road incident and what is the role of an ITS in incident detection. Then authors introduce a closer look to the principle of operation of neural networks and discussed their structure. This paper also presents the method of data processing. There was also described the most popular nowadays' methods of road incident detection and wider development of few selected approaches to the problem of detection using neural networks. The second part of this paper presents personalized approach to the problem of detecting incidents on two selected intersections in Gdynia - ul. Morska/Owsiana (K. Mowiński) oraz ul. 10 Lutego/Świętojańska (T. Marcinkowski). Authors describe the analysis methodology: how to download and use of the data, the precise description and analysis used to compile the algorithm incidents. In the SCILAB software there was created learning classifiers and tested their potentiality. After presenting and comparing results authors summed up their achievements and presented proper conclusions.

Keywords:

Civil engineering: transportation engineering; Incident detection algorithm, neural networks, intelligent transportation systems, traffic safety.

Spis treści

Spis treści	9
1.0. Wstęp (Marcinkowski Tomasz, Mowiński Krystian).....	11
1.1. Cel i zakres pracy.	12
2.0. Podstawowe wiadomości dotyczące wykrywania incydentów.	13
2.1. Incydent drogowy (Mowiński Krystian).....	13
2.2. Proces automatyzacji w wykrywaniu incydentów drogowych (Mowiński Krystian)	13
2.3. Rola systemu TRISTAR w wykrywaniu incydentów drogowych (Mowiński Krystian).	14
2.4. Pętla indukcyjna (Marcinkowski Tomasz)	15
2.4.1. Zasada działania	15
2.4.2. Zastosowania pomiarowe czujnika pętlowego	16
2.4.3. Układ zliczania i pomiar prędkości pojazdów	16
2.5. Parametry oceny algorytmów wykrywania incydentów (Marcinkowski Tomasz).	18
3.0. Sieci neuronowe i przetwarzanie danych.	21
3.1. Podstawowe informacje o sieciach neuronowych (Mowiński Krystian).....	21
3.1.1. Budowa pojedynczego neuronu	21
3.1.2. Struktura sieci.	22
3.1.3. Działanie sieci neuronowej i proces uczenia.	23
3.2. Przetwarzanie danych (Marcinkowski Tomasz)	23
3.2.1. Reprezentacja danych i przetwarzanie wstępne	24
4.0. Algorytmy wykrywania incydentów drogowych.	26
4.1. Wskaźniki wykrywalności wykorzystywane w algorytmach (Marcinkowski Tomasz) ..	26
4.2. Algorytmy wykrywania incydentów w sieciach drogowych (Mowiński Krystian)	26
4.3. Wykorzystanie sieci neuronowych w algorytmach wykrywania incydentów w miejskiej sieci drogowej (Marcinkowski Tomasz).....	28
4.3.1. Wielowarstwowe sieci neuronowe oraz sieci modułowe w podejściu H. Dia i K. Thomas (Marcinkowski Tomasz)	29
4.3.2. Podejście S. Khan i S. Ritchie (Mowiński Krystian)	31
5.0. Metodologia analizy.....	35
5.1. Przedstawienie metodologii działania (Marcinkowski Tomasz)	35
5.2. Pobieranie danych z bazy TRISTAR (Mowiński Krystian)	36
5.3. Konwersja danych z systemu TRISTAR (Marcinkowski Tomasz).....	40
Program do konwersji danych.....	45
5.4. Opis skrzyżowania.....	47
5.4.1. Skrzyżowanie Morska/Owsiana (Mowiński Krystian).....	47
5.4.2. Skrzyżowanie 10 lutego/Świętojańska (Marcinkowski Tomasz).....	49

5.5.	Analiza wypadków	52
5.5.1.	Skrzyżowanie Morska/Owsiana (Mowiński Krystian).....	52
5.5.2.	Skrzyżowanie 10 lutego/Świętojańska (Marcinkowski Tomasz)	61
5.5.	Analiza w programie R.....	69
5.5.1.	Skrzyżowanie Morska/Owsiana (Mowiński Krystian).....	69
5.5.2.	Skrzyżowanie 10 lutego/Świętojańska (Marcinkowski Tomasz)	79
5.6.	Analiza PCA (Marcinkowski Tomasz, Mowiński Krystian)	84
5.7.	Program Scilab. (Marcinkowski Tomasz, Mowiński Krystian).....	87
6.0.	Analiza wyników.	89
6.1.	Skrzyżowanie Morska/Owsiana (Mowiński Krystian)	89
6.2.	Skrzyżowanie 10 lutego/Świętojańska (Marcinkowski Tomasz)	109
6.3.	Zestawienie porównawcze obu skrzyżowań (Mowiński Krystian)	116
6.4.	Propozycja działania systemu wykrywania incydentów w czasie rzeczywistym (Marcinkowski Tomasz).....	117
	Podsumowanie (Marcinkowski Tomasz, Mowiński Krystian)	119
	Literatura.	121
	Spis tabel.....	123
	Spis rysunków.....	124

1.0. Wstęp.

Wysokie koszty zatorów spowodowanych zdarzeniami drogowymi, głównie wynikających z opóźnień w ruchu, zanieczyszczenia powietrza oraz pogorszenia warunków bezpieczeństwa, skłoniły do zwiększenia zainteresowania w tworzeniu wydajnie zautomatyzowanych i skutecznych metod wykrywania incydentów na całym świecie. Incydenty są zdefiniowane jako nieoczekiwane zdarzenia jednorazowe, takie jak wypadki, awarie pojazdów, prace konserwacyjne i inne wydarzenia, które zakłócają normalny przepływ ruchu i powodują zmniejszenie przepustowości skrzyżowania. Takie wypadki stanowią duży procent całkowitych opóźnień w miejskim ruchu ulicznym na całym świecie. Dodatkowo na każdą minutę incydentu potrzeba ok. czterech minut, aby powrócić do przepustowości sprzed incydentu [12]. Dzięki wczesnemu wykryciu incydentów oraz szybkiej reakcji można znacznie zmniejszyć opóźnienia w ruchu oraz poprawić bezpieczeństwo ruchu drogowego i kontroli ruchu w czasie rzeczywistym. Kierowcy mogą być informowani poprzez dostarczanie informacji w czasie rzeczywistym, aby umożliwić im alternatywne trasowanie ruchu, a także może służyć do wcześniejszego wysłania służb ratunkowych. Inteligentne technologie systemów transportowych (ITS) są tak skonstruowane, aby zaspokoić te potrzeby poprzez zaawansowane systemy zarządzania ruchem oraz zaawansowane systemy informatyczne dla podróźnych (ATIS). Również w systemie Tristar są algorytmy umożliwiające takie działania. Jednak, aby system był skuteczny, konieczne jest opracowanie procedur do wykrywania incydentów, które są nie tylko niezawodne, ale i szybkie [1].

Automatyczne wykrywanie incydentów jest w istocie problemem klasyfikacji, w którym dane o ruchu są analizowane i klasyfikowane do jednej z dwóch kategorii (incydent lub nie incydent). W ostatnich dziesięcioleciach powstało wiele algorytmów automatycznego wykrywania incydentów. Większość z nich została opracowana lub proponowana dla autostrad i dróg szybkiego ruchu, jednak w ostatnich latach można spotkać coraz więcej opracowań dotyczących miejskich arterii drogowych. Jednak większość z nich jest dostosowana tylko do konkretnego przypadku (danej sieci drogowej). Struktura tych algorytmów zależy od konkretnych wymagań, złożoności sieci i posiadanych danych o ruchu. W przypadku Gdyńskiej sieci drogowej i systemu Tristar dane o ruchu są zbierane za pomocą podwójnych pętli indukcyjnych, są one osadzone w nawierzchni drogowej. Pętle dostarczają informacji o pojazdach, takich jak: zajętość pętli, czas i długość zajętości pętli, prędkość pojazdu, odległość od poprzedniego pojazdu. Aby otrzymać modele wykrywania incydentów należy dane o ruchu wprowadzić do odpowiednich algorytmów. Do tego celu można stosować metody oparte na analizie szeregów czasowych, sztuczne sieci neuronowe, model Bayesowski, logika rozmyta i inne. Dostępnych jest też kilka innych metod, w tym przetwarzania obrazu wideo. Każdy z tych systemów ma swoje zalety i ograniczenia w odniesieniu do kosztów, wydajności operacyjnej i pokrycia obszaru. Do wykrywania incydentów powodujących blokowanie pasa, przy zbieraniu danych o ruchu z pętli indukcyjnych, literatura sugeruje wykorzystanie sztucznych sieci

neuronowych, które oferują najwyższy wskaźnik wykrywalności i najniższy wskaźnik fałszywych alarmów [1].

1.1. Cel i zakres pracy.

Celem niniejszej pracy jest sprawdzenie czy z wykorzystaniem sieci neuronowej, do której wprowadzono dane z pętli indukcyjnych, montowanych na skrzyżowaniach w ramach systemu TRISTAR, można zbudować efektywny algorytm wykrywania incydentów w miejskiej sieci ulicznej Gdyni. Zadanie to wykonano na podstawie dwóch skrzyżowań:

- Morska – Owsiana (nr 102),
- 10 Lutego – Świętojańska (nr 235).

Zakres pracy:

- Przegląd dostępnej literatury na temat algorytmów automatycznej detekcji incydentów na autostradach i w miejskiej sieci ulicznej.
- Przegląd dostępnej literatury dotyczącej sieci neuronowych, a także ich wykorzystanie przy budowaniu algorytmów wykrywania incydentów.
- Konwersja danych z pętli indukcyjnych, tak, aby mogły zostać skutecznie wykorzystane do wykrywania incydentów w sieci neuronowych, w tym:
 - Stworzenie bazy danych do przechowywania wartości zebranych z pętli indukcyjnych.
 - Stworzenie programu do konwersji danych (PHP/SQL).
 - Normalizacja i standaryzacja danych.
- Analiza w programie R, czy przyjęty model danych jest odpowiedni do zastosowania w sztucznych sieciach neuronowych.
- Stworzenie nauczyciela odpowiedniego dla danego skrzyżowania, który będzie pozwalał na wykrywanie incydentów na tym skrzyżowaniu.
- Sprawdzenie wykrywalności badanych incydentów i analiza otrzymanych wyników.

Niniejsza praca jest wstępem do budowy algorytmu automatycznej detekcji incydentów na skrzyżowaniach w Gdyni. Przeprowadzone analizy mają dać odpowiedź, czy w oparciu o sieci neuronowe można zbudować w pełni funkcjonalny system, który będzie alarmował dyspozytora ruchu o zaistniałych incydentach na skrzyżowaniu przy odpowiednim poziomie wykrycia oraz małym odsetku fałszywych alarmów.

2.0. Podstawowe wiadomości dotyczące wykrywania incydentów.

2.1. Incydent drogowy

Incydentem drogowym nazywamy zaistnienie nieprzewidzianego i nieprzewidywalnego dla kierowcy zdarzenia, które ma wpływ na bezpieczeństwo uczestników ruchu drogowego, jak i również w sposób znaczący ogranicza przepustowość sieci drogowej. Zatłoczenie spowodowane przez incydenty jest przyczyną dodatkowych kosztów w ruchu drogowym, będących skutkiem wzrostu strat czasu, zużycia paliwa oraz wypadków wtórnych, będących wynikiem najechania na pojazdy stojące lub przemieszczające się w kolejkach. Incydenty można podzielić na mniej lub bardziej istotne. Do najistotniejszej grupy incydentów należą wypadki drogowe. W większości przypadków potrzebna jest interwencja służb porządkowych, a to z kolei wiąże się z zatrzymaniem ruchu na określonym odcinku drogi. Innym typem są zdarzenia związane z zawodnym działaniem infrastruktury, które mogą znacznie utrudnić ruch na drodze. Najłżejszym, a zarazem najmniej inwazyjnym typem incydentu są zajętości pasa. Mogą powodować tworzenie się kolejek i znaczne ograniczenia przepustowości [3,7].

2.2. Proces automatyzacji w wykrywaniu incydentów drogowych.

Odpowiednia szybka reakcja wykrywania zdarzeń drogowych jest niezbędna do uruchomienia całego szeregu zadań mającego na celu jak najszybszy powrót do optymalnej sytuacji drogowej. Dzięki stosowaniu systemów wykrywania incydentów, zarządcy dróg uzyskują możliwość ostrzeżenia kierowców o niebezpieczeństwie oraz kierowania ruchu na trasy alternatywne. Szybka likwidacja zatłoczenia i przywrócenie normalnych warunków ruchu wymaga jak najszybszego wykrycia lokalizacji incydentu i jego rodzaju, a to w przypadku wykrycia wypadku drogowego skutkuje sprawnym dojazdem i przeprowadzeniem akcji ratowniczej. Pozytywnym następstwem tych działań jest wstrzymanie ekspansji zatłoczenia oraz zmniejszenia ciężkości wypadków, poprzez szybsze udzielenie pomocy ofiarom. Wykrycie i weryfikacja wypadku drogowego powinno być priorytetowym działaniem. Zautomatyzowanie wszystkich procesów pozwoli na efektywne i szybkie działanie w takich sytuacjach. Najważniejszymi przesłankami do stosowania automatyzacji w wykrywaniu zdarzeń są:

- odpowiednie wykorzystanie środków telematiki transportu potrafi redukować czas reakcji i operowania służb ratowniczych nawet o ok.30%,
- wykorzystanie alarmowych wywołań, automatycznie generowanych przez odpowiednie systemy zwiększają prawdopodobieństwo przeżycia ewentualnej ofiary wypadku do nawet kilkunastu procent dzięki szybkiemu poinformowaniu odpowiednich służb ratowniczych

- zastosowanie systemów zarządzania incydentami pozwala na zminimalizowanie okresu ekspozycji na ryzyko wystąpienia zdarzeń wtórnych [7,8].

Automatyczne wykrywanie incydentów (AID) jest integralną częścią systemów zarządzania. Systemy wykrywania incydentów obejmują dwa główne składniki: system detekcji ruchu oraz algorytm wykrywania incydentów. System wykrywania ruchu zbiera informacje o ruchu niezbędne do wykrywania zdarzenia. Algorytm w czasie rzeczywistym interpretuje te dane oraz stwierdza obecność lub brak incydentu. Jak stwierdzono wcześniej, detektory pętli indukcyjnych, osadzone w nawierzchni, są zwykle używane do uzyskania danych o ruchu. Dane zawierają prędkość, zajętość i inne parametry, które przekazywane są do Centrum Sterowania Ruchem (CSR) w czasie zbliżonym do rzeczywistego zaraz po wystąpieniu wzbudzenia pętli. Dane tego typu stanowią wejście do algorytmu detekcji incydentu, która podnosi alarm, aby wskazać na obecność wypadku na danym skrzyżowaniu.[1].

2.3. Rola systemu TRISTAR w wykrywaniu incydentów drogowych.

Zintegrowany System Zarządzania Ruchem TRISTAR pozwala na sterowanie ruchem w automatycznym trybie na obszarze obejmującym całe Trójmiasto poprzez stosowanie zaawansowanych technologii z dziedziny Inteligentnych Systemów Transportowych. W skład systemu wchodzi szereg systemów i podsystemów wspomagających konkretne aspekty drogowe [18].

Do najważniejszych systemów wspomagających, biorących udział w opracowaniu systemu wykrywania incydentów należą:

- a) System monitorowania i nadzoru ruchu pojazdów.

Jego zadaniem jest gromadzenie i dostarczanie szczegółowych danych odnośnie liczby i rodzaju pojazdów biorących udział w ruchu na obszarze objętym systemem. System zbiera różne informacje, takie jak: czasy przejazdu na odcinkach, czy prędkości średnie. Informacje te dostarczane są poprzez stacje pomiaru ruchu, bazujące na zainstalowanych w jezdniach pętlach indukcyjnych. Wspomagającą rolę pełni również monitoring zainstalowany na wybranych skrzyżowaniach [14].

- b) System zarządzania bezpieczeństwem ruchu.

System mający na celu zmniejszenie ilości kolizji i wypadków, a zarazem zmniejszenie ilości osób poszkodowanych. Głównym jego celem jest rejestracja prędkości i rejestracja przejazdów na czerwonym świetle [15].

- c) System sterowania ruchem drogowym.

Został wdrożony w celu optymalizacji sterowania sygnalizacją świetlną przez automatyczne, a także wspomagane przez operatora dostosowywanie parametrów programów sygnalizacji do

zmiennych warunków ruchu w czasie rzeczywistym. Dane na temat warunków i parametrów ruchu dostarczane są do centralnego systemu dzięki zainstalowaniu detektorów pojazdów w nawierzchni oraz urządzeń wideodetekcji na masztach sygnalizacji świetlnej. Analiza i wykorzystanie tych danych umożliwi stworzenie algorytmów wykrywających incydenty w sieci miejskiej [16].

Moduł Wykrywania Zdarzeń Drogowych będzie częścią Systemu Sterowania Ruchem Drogowym. Na dzień dzisiejszy zakłada się, że system TRISTAR będzie miał możliwości zastosowania modułu na wybranych skrzyżowaniach w obrębie systemu.

2.4. Pętla indukcyjna

Indukcyjny czujnik pętlowy, inaczej popularnie nazywany pętlą indukcyjną jest jednym z czujników najczęściej stosowanych podczas pomiarów parametrów ruchu drogowego. Przyczyną tej popularności są jego dobre właściwości użytkowe i metrologiczne, m.in. odporność na wpływ warunków atmosferycznych, niska cena, prosta budowa. Indukcyjne czujniki pętlowe stosowane w pomiarach parametrów ruchu wykonywane są najczęściej w formie prostokątnych pętli o wymiarach od około 1m x 1m do 3m x 3m. Wymiary stosowanych czujników są podyktowane różnym rodzajem zadań, do których są przeznaczone [13].




Rysunek 1. Pętla indukcyjna na jednym ze skrzyżowań [15].

2.4.1. Zasada działania

Podstawą działania indukcyjnego czujnika pętlowego jest zjawisko prądów wirowych. Zjawisko to występuje wszędzie tam gdzie w obszarze występowania zmiennego pola magnetycznego znajdzie się obiekt metalowy. Pole magnetyczne napotykać obiekt wykonany z metalu wnika do niego indukując przepływ prądu elektrycznego. Indukcyjne czujniki pętlowe

zasilane są przeważnie sinusoidalnym napięciem przemiennym. Prąd płynący przez zwoje czujnika pętlowego wytwarza sinusoidalnie zmienne pole magnetyczne (pole pierwotne) w przestrzeni dookoła niego. Pole to natrafiając na obiekt metalowy znajdujący się w jego pobliżu indukuje w nim prądy wirowe, które wytwarzają sinusoidalnie zmienne pole magnetyczne, które osłabia pole pierwotne. Skutkiem tego pole wypadkowe posiada zmniejszony moduł i jest przesunięte w fazie. W wyniku zaistnienia zjawiska, impedancja czujnika obserwowana z jego zacisków także zmienia się zarówno co do modułu jak i kąta fazowego. To właśnie w tej zmianie, odnoszonej do pierwotnych parametrów czujnika zawarta jest informacja o obiekcie, jego położeniu, gabarytach, rodzaju materiału, prędkości poruszania się, typu obiektu wg przyjętej klasyfikacji [13].



Rysunek 2. Ilustracja zjawiska powstawania prądów wirowych [13].

2.4.2. Zastosowania pomiarowe czujnika pętlowego

Podstawowymi parametrami, które mogą być bezpośrednio mierzone przez system wyposażony w pojedynczy czujnik lub parę czujników są:

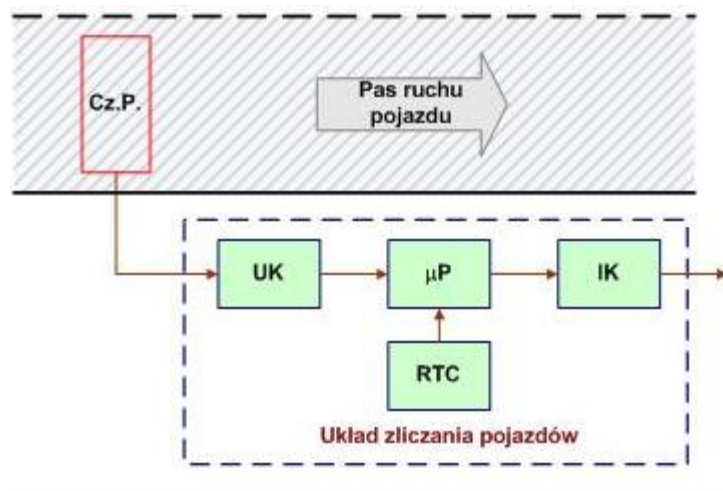
- czas pojawienia się pojazdu na stanowisku pomiarowym,
- prędkość pojazdu,
- długość pojazdu,
- liczba pojazdów przejeżdżających przez stanowisko pomiarowe w zadanym interwale czasu,
- odległości czasowe pomiędzy kolejnymi pojazdami,

Znajomość wymienionych parametrów, charakterystycznych dla danego pojazdu, pozwala na ocenę podstawowych parametrów charakteryzujących ruch na badanym odcinku drogi: m.in.: gęstość ruchu, przepływ pojazdów, prędkości średnie w czasie, zajętość pasa ruchu [13].

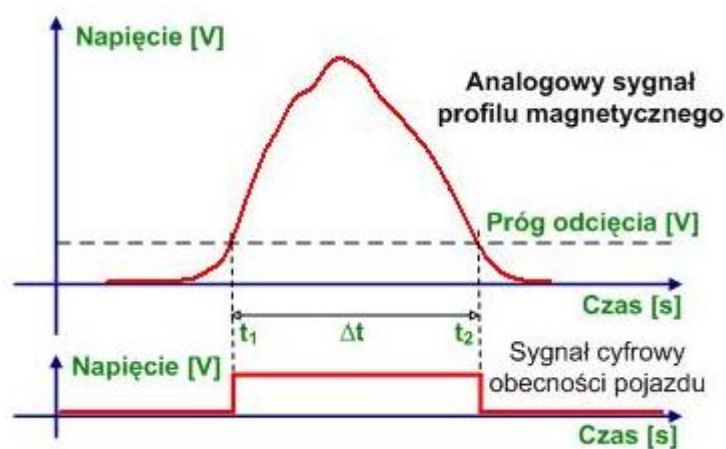
2.4.3. Układ zliczania i pomiar prędkości pojazdów

Sygnał analogowy profilu pojazdu jest podstawowym sygnałem wyjściowym układu kondycjonowania. Zamieniany on jest na cyfrowy sygnał w formie prostokątnych impulsów o czasie trwania równym czasowi pozostawania pojazdu nad czujnikiem (rys. 3). Impulsy

następnie wyzwalają w systemie mikroprocesorowym zapis wystąpienia zdarzenia, czyli przejazd pojazdu przez stanowisko pomiarowe. Bezwzględny czas przejazdu pojazdu jest zapisywany w bazie danych gromadzonych w systemie. Podstawą określenia czasu przejazdu jest zegar czasu rzeczywistego. (rys.4).




Rysunek 3. Układ pomiarowy do zliczania pojazdów (Cz. P. – czujnik; UK – układ kondycjonowania sygnału; μP – system mikroprocesorowy; IK – interfejsy telekomunikacyjne; RTC – zegar czasu rzeczywistego) [13].




Rysunek 4. Analogowy sygnał profilu magnetycznego i odpowiadający mu sygnał cyfrowy obecności pojazdu [13].

Pomiar prędkości z wykorzystaniem indukcyjnych czujników pętlowych odbywa się w układzie wykorzystującym dwa czujniki umieszczone w znanej odległości. (rys.5) Rozwiązanie to zapewnia dużą dokładność pomiaru i powinno być stosowane wszędzie tam, gdzie dokładność ma szczególnie istotne znaczenie lub gdzie istniejący układ czujników pozwala na jej stosowanie. Sygnały profilu magnetycznego każdego z czujników przekształcane są na cyfrowe sygnały na podstawie progów odcięcia. Następnie mierzony jest czas pomiędzy przednimi zboczami tych sygnałów. Prędkość obliczana jest z zależności $v=s/\Delta t$, gdzie s –

odległość przednich boków czujników, a Δt – czas pomiędzy przednimi zboczami sygnałów cyfrowych obecności pojazdu. (rys.6) [13].



Rysunek 5. Układ pomiaru prędkości za pomocą dwóch czujników pętlowych (Cz. P. – czujnik; UK1,2 – układy kondycjonowania sygnału; μP – system mikroprocesorowy; IK – interfejsy telekomunikacyjne; RTC – zegar czasu rzeczywistego) [13].



Rysunek 6. Zależności czasowe sygnałów generowanych przez pojazd podczas pomiaru prędkości za pomocą dwóch czujników pętlowych [13].

2.5. Parametry oceny algorytmów wykrywania incydentów.

Incydenty są zdefiniowane jako zdarzenia, które powodują zmniejszenie przepustowości drogi lub skrzyżowania. Oceniając wydajność algorytmu wykrywania incydentów stosuje się następujące kryteria oceny (najlepiej, aby były obliczane na podstawie niezależnego zestawu danych zdarzeń, które nie zostały wykorzystane w rozwoju lub kalibracji algorytmu):

- Detection rate (DR).

Określa się jako liczbę wykrytych zdarzeń podzielony przez całkowitą liczbę zdarzeń, które wystąpiły w czasie działania algorytmu. Pożądana jest skutecznością rozpoznawania większa niż 90%. Dodatkowym wymogiem jest to, że zdarzenie może być wykryte w bardzo krótkim

czasie (na przykład 5 minut) od wystąpienia zdarzenia. Jeśli zdarzenie nie jest wykrywane w tym czasie, to jest uważane niewykryte.

$$DR = \frac{\text{liczba wykrytych incydentów}}{\text{całkowita liczba incydentów}} \cdot 100\% \quad \text{Wzór 2.1.}$$

- False alarm rate (FAR).

Jeśli algorytm wykrywania incydentów podnosi alarm, podczas gdy w rzeczywistości nie było incydentu, stanowi to fałszywy alarm. Poziom fałszywych alarmów (FAR) można określić na dwa sposoby, w zależności od tego, czy jest obliczana on-line, czy off-line. Poziom fałszywych alarmów podczas testów on-line, FAR jest zdefiniowany jako:

$$FAR_{on} = \frac{\text{liczba przedziałów, które dały fałszywy alarm}}{\text{całkowita liczba przedziałów, na których model był stosowany}} \cdot 100\% \quad \text{Wzór 2.2.}$$

Podczas testowania wydajności algorytmu opartego na zebranych wcześniej danych (czyli testowania off-line), początek i zakończenie incydentu może być zwykle określone. Pozwala to na określenie początku i zakończenia incydentów, a w konsekwencji do obliczenia, ile razy algorytm został stosowany w warunkach bez incydentów. Dlatego FAR dla off-line jest zdefiniowany jako:

$$FAR_{off} = \frac{\text{liczba przedziałów, które dały fałszywy alarm}}{\text{całkowita liczba przedziałów bez incydentów w zbiorze danych}} \cdot 100\% \quad \text{Wzór 2.3.}$$

- Mean time-to-detect (MTTD).

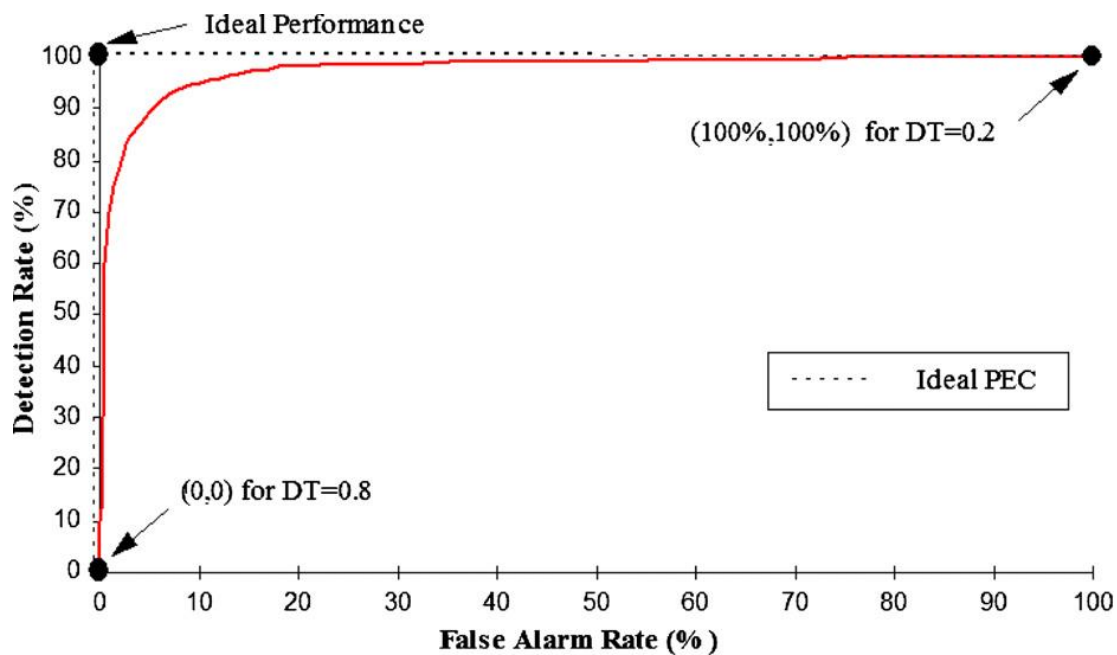
Czas do wykrycia (TTD) zdarzenia jest zdefiniowany jako różnica między czasem wystąpienia incydentu (t_{io}), a czasem, w którym został wykryty przez algorytm (t_{ia}). Czas zdarzenia nie zawsze jest dokładnie znany, ale można go wywnioskować z danych detektora pętli lub rejestrów prowadzonych przez centra kontroli ruchu. Przy ocenie skuteczności algorytmu dla wielu incydentów podaje się średni czas do wykrycia (MTTD) zbioru (n) incydentów. W związku z tym MTTD jest zdefiniowany jako:

$$MTTD = \frac{1}{n} \cdot \sum_{i=1}^n (t_{ia} - t_{io}) \quad \text{Wzór 2.4.}$$

- Performance envelope curve area (PECA).

Realizacja algorytmów wykrywania incydentów w zakresie DR, FAR MTTD mogą się różnić w zależności od wyboru odpowiednich progów decyzyjnych związanych z konkretnym algorytmem. Wybrane wartości w klasyfikacji danych wejściowych (w przypadku sieci neuronowych konstrukcja nauczyciela) wpływają znacząco na otrzymane wartości DR, FAR i MTTD. Zależność DR/FAR (pokazano na poniższym rysunku) jest nazywana krzywą obwiedni wydajność (PEC) modelu. W idealnej wydajności, DR będzie 100%, a FAR będzie zero. Można to określić ilościowo przez obszar pod krzywą (PECA) oraz nachylenie krzywej (w

szczegółności dla niskich wartości FAR). Ta procedura jest szczególnie użyteczna, ponieważ ocena skuteczności modelu wyznaczana jest w oparciu o jeden wskaźnik (obszar pod PEC) [1].




Rysunek 7. Zależność DR/FAR [1].

3.0. Sieci neuronowe i przetwarzanie danych.

3.1. Podstawowe informacje o sieciach neuronowych.

Wykorzystanie sieci neuronowych w różnych dziedzinach nauki na przestrzeni ostatnich kilkunastu jest niezwykle popularne i ich działanie jest wciąż unowocześniane. Są one wyjątkowo wygodnym narzędziem, bardzo przydatnym w realizacji wielu praktycznych zadań. Przede wszystkim nadają się one do rozwiązywania problemów związanych z przetwarzaniem i analiza danych oraz z predykcją, sterowaniem lub klasyfikacją. Istotną rzeczą wzbogacającą możliwości ich zastosowania jest ich charakter nieliniowy. Sieci pozwalają także na kontrolę nad złożonymi problemami wielowymiarowości. Największym jednak atutem jest prawdopodobnie łatwość ich użycia. Same konstruują one potrzebne użytkownikowi modele, ponieważ automatycznie uczą się wykorzystując podane przez niego przykłady. Zadaniem użytkownika jest zgromadzenie reprezentatywnych danych dotyczących interesującej go zależności, a następnie uruchomienie algorytmu uczenia, mającego na celu wytworzenie w pamięci sieci potrzebnej struktury danych w postaci tzw. współczynników wagowych. Jedyną rzeczą na jakiej skupić musi się użytkownik to sposób wyboru i przygotowania danych, a także dokonanie wyboru właściwego rodzaju sieci neuronowej oraz zadać sobie trud interpretacji rezultatów. Podsumowując sieci neuronowe mogą być stosowane wszędzie tam, gdzie pojawiają się problemy związane z tworzeniem modeli matematycznych pozwalających automatycznie (poprzez tzw. proces uczenia) odwzorować różne złożone zależności pomiędzy pewnymi sygnałami wejściowymi, a wybranymi sygnałami wyjściowymi [17].



Rysunek 8. Model złożonego systemu, możliwy do realizacji w postaci sieci neuronowych.

3.1.1. Budowa pojedynczego neuronu

Działania sztucznego neuronu jest w pewnym sensie oparte na działaniu biologicznych systemów neuronowych. Twórcy sztucznych sieci zdecydowali, że sztuczny neuron powinien być zdefiniowany następująco:

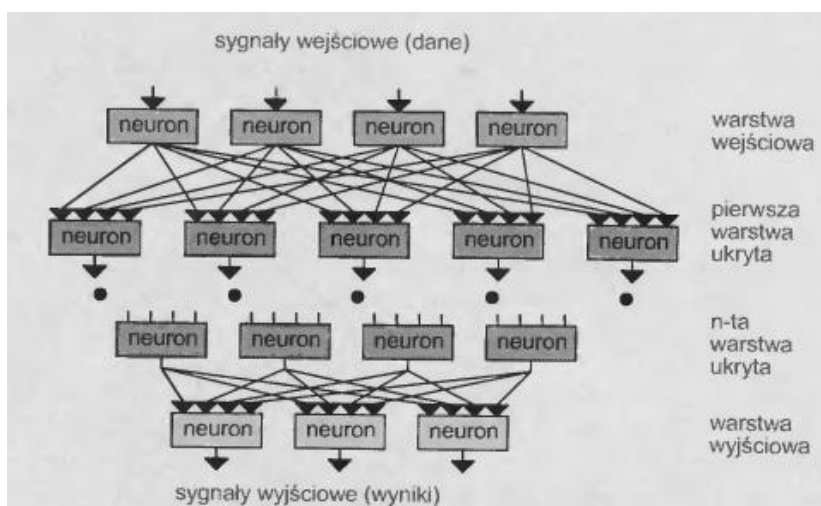
- Jest elementem, do którego dociera pewna liczba wejściowych sygnałów (wartości) – albo danych pierwotnych, podanych do sieci z zewnątrz, albo sygnałów pośrednich (z wyjść innych neuronów sieci),
- Każda wartość wprowadzona jest do neuronu przez połączenie o pewnej wadze,
- Każdy neuron posiada pojedynczą wartość progową, która określa jak silne musi być jego pobudzenie, by doszło do tzw. zapłonu,

- w neuronie obliczana jest ważona suma wejść (suma sygnałów wejściowych X określone współczynniki wagowe), po czym odejmowana jest od niej wartość progowa. Ta wartość określa pobudzenie.
- Sygnał reprezentujący łączne pobudzenie neuronu przekształcany jest z kolei przez ustaloną funkcję aktywacji neuronu (tzw. funkcja przejścia neuronu), taka wartość obliczona przez tą funkcję jest ostateczną wartością wyjściową neuronu.

Zachowanie neuronu jest silnie uzależnione od rodzaju użytej funkcji. Można zastosować funkcję progową (działanie *wszystko albo nic* – „0” lub „1”) albo, znacznie częściej stosowana w sztucznych sieciach neuronowych, funkcja aktywacji w postaci sigmoidalnej – dostarczającej sygnałów o wartości zmieniającej się w sposób ciągły [17].

3.1.2. Struktura sieci.


Jeśli dana sieć ma posiadać wartość użytkową musi mieć wejścia, tzw. neurony wejściowe (czyli służące do wprowadzania wartości zmiennych obserwowanych na zewnątrz) oraz wyjścia, inaczej neurony wyjściowe (wyznaczające wynik obliczeń). Oprócz tego dość ważnym elementem są tzw. neurony ukryte, pośredniczące w całym procesie. Tworzą one całe warstwy i nie ma możliwość ich bezpośredniej obserwacji ani od strony wejść, ani od strony wyjść. Wszystkie neurony muszą zostać wzajemnie połączone, a to stawia przed twórcą sieci problem odpowiedniego doboru jej struktury. Jedną z kluczowych kwestii jest, czy w sieci będzie występować sprzężenie zwrotne. W prostych sieciach jednokierunkowych sygnał przepływa w jednym kierunku – od wejść, poprzez neurony ukryte, do wyjść. Taki typ sieci charakteryzuje się zawsze stabilnym zachowaniem. Natomiast, gdy sieć posiada wbudowane sprzężenie zwrotne (zawiera powrotne połączenia od późniejszych do wcześniejszych neuronów) to może wykonywać bardziej skomplikowane zadania. Minusem takiego rozwiązania jest fakt, że na skutek krążenia sygnałów w takiej sieci może ona zachowywać się niestabilnie.



Rysunek 9. Schematyczna budowa typowej sieci neuronowej [2].

3.1.3. Działanie sieci neuronowej i proces uczenia.

Działanie sieci neuronowej jest wypadkową działania poszczególnych neuronów oraz interakcji, jakie pomiędzy nimi zachodzą. Pojedynczy neuron, patrząc na sytuację z matematycznego punktu widzenia, realizuje operację skalarnego iloczynu wektora sygnałów wejściowych oraz wektora wag. Wzajemne geometryczne stosunki pomiędzy tymi wektorami uzależniają odpowiedź neuronu. Właściwą geometrię położenia wektorów wag, która gwarantuje poprawność działania sieci, uzyskuje się w procesie uczenia, który może być interpretowany jako metoda automatycznego poszukiwania takiego zestawu współczynników wagowych występujących we wszystkich neuronach całej sieci, który gwarantuje najmniejszą wartość sumarycznego błędu popełnianego przez sieć (sumowanie odbywa się po zbiorze różnych zadań stawianych sieci). W wyniku stosowania odpowiedniego algorytmu uczenia (np. wsteczna propagacja błędów) sieć może systematycznie zmniejszać ten błąd w trakcie kolejnych epok czasu uczenia, dzięki czemu będzie można zaobserwować poprawę jej funkcjonowania [2].



Rysunek 10. Istota metody zmiany wektora wag podczas procesu uczenia sieci [2].

3.2. Przetwarzanie danych

Sztuczna sieć neuronowa stanowi niezwykle uniwersalny układ aproksymacyjny, który radzi sobie z odwzorowaniem wielowymiarowych zbiorów danych, jednakże niejednorodna reprezentacja wielkości występujących w układzie, rozmiar wektora tych wielkości czy po prostu występujące zakłócenia wpływają na niemożność wykorzystania sieci do określonego zadania. Wymagane jest w takim wypadku odpowiednie przetworzenie wstępne, czyli transformacja danych pierwotnych do takiej reprezentacji danych, która będzie odpowiednia dla wykorzystania na wejściu sieci neuronowej.

Przeważnie rzeczywiste obiekty lub zjawiska są na ogół opisywane znaczną liczbą cech. Należy założyć, że nie każda z nich będzie równie przydatna i przefiltrować jedynie te z nich, które będą ujęte w wektorze cech na wejściu sieci neuronowej. W związku z

wykorzystaniem technik komputerowych wstępna obróbka najczęściej składa się na liczbową reprezentację sygnałów, czyli przekształcenie wszystkich próbek do jednolitej postaci lepiej odzwierciedlającej obserwowane cechy, a jednocześnie pozwalającej na dokładniejsze przeprowadzenie procesów obliczeniowych. Czasami niezbędnym procesem jest również filtracja sygnałów, polegająca na usunięciu szumów oraz zakłóceń, co ma prowadzić do uwydatnienia pożądanych składowych lub parametrów [2].

3.2.1. Reprezentacja danych i przetwarzanie wstępne

Ze względu na charakter niesionych informacji oraz poziom jej przetworzenia rozróżnia się następujące typy danych:

- Dane pierwotne
 - Obrazy oraz ich zbiory i sekwencje
 - Szeregi czasowe
 - Dane rejestrowane w czasie i przestrzeni (wielowymiarowe)
 - Zbiory opisów lub obserwacji
 - Sekwencje symboli pochodzących z danego alfabetu
- Dane wstępnie przetworzone w postaci wyekstrahowanych cech
- Zbiory danych zorganizowane w tabelaryczne systemy informacyjne, zawierające zestawy obrazów wejściowych (dla uczenia bez nadzoru) oraz ewentualne zbiory wartości docelowych (dla uczenia z nadzorem) [5].

Głównym celem wstępnego przetwarzania jest pozyskanie danych pierwotnych, a następnie polepszenia ich jakości i wygenerowanie zbiorów cech. Etap ten decyduje o tym, czy zbiory cech przypisanych poszczególnym stanom obiektu bądź klasom jego zachowań będą separowalne. Sam proces ekstrakcji to redukcja danych pomiarowych oraz wzmocnienie kontrastów między próbkami reprezentującymi różne stany obiektu. Wybór metody jest uzależniony od reprezentacji danych oraz celu ich przetwarzania (rodzaju zagadnienia). Innym kryterium decydującym mogą być koszty tych operacji, albo wymagania dotyczące szybkości przetwarzania [5]. W dalszej części skupiono się na opisie zastosowanych sposobów przetwarzania danych na potrzeby pracy. Zastosowano następujące modele konwersji danych:

❖ Normalizacja min-max danych

Przy stosowaniu tego typu normalizacji danych otrzymujemy wektory, których wartości cech zawarte są w przedziale zamkniętym $\langle 0,1 \rangle$. Ten typ transformacji jest przeprowadzany z wykorzystaniem następującego wzoru:

$$a'_i = \frac{a_i - a_{i_min}}{a_{i_max} - a_{i_min}} \quad \text{Wzór 3.1.}$$

gdzie:

a_{i_max} – maksymalna wartość występująca w zbiorze dla i-tej cechy,

a_{i_min} – minimalna wartość dla i-tej cechy.

Operacja normalizacja powinna być wykonana dla wszystkich wartości ze zbioru przeznaczonego do nauki oraz dla zbioru testowego (tzw. globalna). Dla wszystkich wartości użyte są te same a_{i_max} i a_{i_min} . Normalizacja nie uwzględnia rozkładu wartości danej cechy, w związku z tym w przypadku wystąpienia wartości znacznie różniących się od przeciętnej, nastąpi „ściśnięcie” wszystkich wartości w bardzo wąskim narzuconym przedziale.

❖ Standaryzacja danych

Standaryzacja jest transformacją wykorzystującą rozkład wartości w poszczególnych cechach:

$$a'_i = \frac{a_i - \bar{a}_i}{\sigma_i(a)} \quad \text{Wzór 3.2.}$$

gdzie:

$$\bar{a}_i = \frac{1}{n} \sum_l a_{il} - \text{średnia wartości w zbiorze}$$

$$\sigma_i(a) = \frac{1}{n-1} \sum_l (a_{il} - \bar{a}_i)^2 - \text{odchylenie standardowe wartości w zbiorze}$$

Wynikiem standaryzacji jest wektor cech, których średnia wartość jest równa 0, natomiast odchylenie standardowe jest równe 1. Taki sposób wpływa na to, że wszystkie z cech mają jednakowy wkład do wartości odległości. Przy stosowaniu standaryzacji należy zachować ostrożność, gdyż może zdarzyć się sytuacja, gdzie dla jednego z wektorów odchylenie standardowe będzie bliskie zeru. Konsekwencją może być nieumyślne wprowadzenie do danych dużego szumu. Oczywiście w przypadku, gdy odchylenie będzie zerowe otrzymana wartość będzie nieokreślona (spowodowane dzieleniem przez „0”), dlatego przed zastosowaniem tego typu transformacji danych należy usunąć tzw. flat pattern (pl. „płaskie wzorce”) [5].

4.0. Algorytmy wykrywania incydentów drogowych.

4.1. Wskaźniki wykrywalności wykorzystywane w algorytmach.

Metody wykrywania zdarzeń wykorzystują algorytmy, które pozwalają na analizę zmian parametrów ruchu takich, jak prędkość pojazdów, natężenie ruchu oraz zajętość detektorów. W celu porównania skuteczności poszczególnych algorytmów wykorzystuje się trzy główne parametry - wskaźnik wykrywalności (detection rate - DR), wskaźnik fałszywych alarmów (false alarm rate - FAR) oraz czas do wykrycia zdarzenia (time to detect - TTD). Wskaźnik wykrywalności definiowany jest jako stosunek ilości wykrytych zdarzeń do całkowitej ich liczby. Wartość wskaźnika jest zależna od sposobu definiowania zdarzenia. W niektórych analizach uwzględnia się również zdarzenia występujące jedynie na pasach ruchu, natomiast w niektórych uwzględnia się również zatrzymanie pojazdu na poboczu drogi. Rozpoznawalność zdarzeń, w efekcie których pojazdy zostają unieruchomione na poboczu, nie przyczyniające się do przerwania potoku ruchu lub jego zakłócenia jest znacznie mniejsza. Czas wykrycia zdarzenia zdefiniowany jest jako przedział czasowy od momentu zaistnienia zdarzenia na miejscu do czasu jego wykrycia, (nie uwzględniając czasu, który potrzebny jest na jego weryfikację). Wskaźnik fałszywych alarmów jest definiowany jako procentowy udział liczby błędnie wykrytych zdarzeń w całkowitej liczbie wykrytych zdarzeń. Sposoby określenia tego parametru bywają jednak zróżnicowane, ze względu na odmienne sposoby kalkulacji. Zazwyczaj wskaźnik jest wyższy, im większa ilość podejmowanych decyzji w jednostce czasu oraz im większa ilość detektorów w sieci. Często definiuje się dodatkowy wskaźnik, uwzględniający liczbę fałszywych alarmów przypadających na stację detekcyjną w jednostce czasu. Wartości opisywanych wskaźników są od siebie zależne. Wzrost wskaźnika wykrywalności jest równoznaczny ze wzrostem wskaźnika fałszywych alarmów, jak i również ze wzrostem średniego czasu wykrycia zdarzenia. Analogicznie mniejsze wskaźniki fałszywych alarmów przekładają się na mniejsze wartości wskaźnika wykrywalności, związane jest to z mniejszą czułością algorytmu. Czas wykrycia zdarzenia nie może być zbyt długi, dlatego należy dążyć do zachowania równowagi pomiędzy parametrami skuteczności zastosowanej metody [6, 8, 11].

4.2. Algorytmy wykrywania incydentów w sieciach drogowych

W okresie ostatnich 30 lat rozwinięto i sklasyfikowano główne cztery grupy algorytmów wykrywania incydentów:

- algorytmy bazujące na modelach wzorcowych,
- algorytmy bazujące na teorii katastrofy,
- algorytmy bazujące na obliczeniach statystycznych
- algorytmy bazujące na sztucznej inteligencji.

W pracy pokrótce zostaną przybliżone pierwsze trzy algorytmy stosowane w sieciach drogowych, głównie jednak na drogach szybkiego ruchu oraz autostradach. Szerzej zostanie opisane wykorzystanie sieci neuronowych.

Algorytmy bazujące na modelach wzorcowych są najpowszechniejszymi algorytmami wykorzystywanymi na autostradach. Korzystają one z informacji o parametrach potoku ruchu, które otrzymywane są z pętli indukcyjnych - natężenie ruchu, zajętość detektora, a następnie porównując te dane z teoretycznymi wzorami wyprowadzonymi z danych historycznych. Grupa tego typu algorytmów wymaga wstępnego wyznaczenia progów, do których parametry ruchu byłyby porównywane. Ustanowienie progów nie jest łatwe i należy do czasochłonnych czynności. Etap ten jest jednak bardzo ważny, więc nie może być lekceważony z uwaga na to, że dokładność określenia progów jest kluczowym elementem dla późniejszego funkcjonowania algorytmów. Spośród przykładowych algorytmów należących do tej grupy można wymienić:

- algorytm kalifornijski (inaczej TSC), wraz z jego późniejszymi modyfikacjami (algorytmy TSC 7 i TSC8),
- algorytm APID,
- algorytm PATREG
- algorytm Minnesota [6, 10].

Algorytmy bazujące na teorii katastrofy uwzględniają wystąpienie nagłej, dyskretnej zmiany w jednej ze zmiennych, podczas gdy pozostałe zależne zmienne wykazują ciągle zmiany w czasie. Do rozważanych zmiennych zalicza się prędkość pojazdów, zajętość detektora oraz natężenie ruchu. W przypadku znacznego, nagłego spadku prędkości, ale bez jednoczesnego wzrostu zajętości detektora i natężenia ruchu, uruchomiony zostaje alarm. Zastosowanie tego typu algorytmów pozwala na odróżnienie zaistnienia incydentu od wystąpienia zatłoczenia drogi. Następstwem zdarzenia jest przyrost kolejki pojazdów oraz nagły, znaczny spadek prędkości. Algorytmy oparte na teorii katastrofy różnią się od tych bazujących na wzorcach tym, że metoda wzorcowa bazuje na określaniu zmian pojedynczych zmiennych w uprzednio określonych progach, natomiast w teorii katastrofy przyrównuje się wiele zmiennych w czasie, na zasadzie porównanie ich z wcześniejszymi trendami zmienności danych. Przykładem algorytmu z tej grupy jest algorytm McMaster [11].

W algorytmach bazujących na obliczeniach statystycznych znaczną rolę pełnią prognozy danych wykorzystujące szeregi czasowe. Są one porównywane z bieżącymi danymi o potoku ruchu. Algorytmy klasyfikują jako incydenty wszystkie zmiany parametrów ruchu, które wykraczają poza prognozowany zakres wartości parametrów. Istotną zaletą stosowania tych algorytmów jest możliwość uwzględnienia dużej ilości danych. Do tej grupy algorytmów można zaliczyć:

- algorytm HIOCC (High Occupancy Algorithm),
- algorytm ARIMA (Auto-Regressive Integrated Moving-Average),
- algorytm SND (Standard Normal Deviates),
- algorytm DES (double exponential smoothing),
- algorytm DELOS (Detection Logic with Smoothing),

- algorytm Bayesian
- algorytm pojedynczego detektora SSID (Single-Station Incident Detection), Low Pass Filter [6, 8, 10].

Sztuczna inteligencja jest stosunkowo najmłodszą grupą algorytmów wykorzystywaną w procesach automatycznego wykrywania zdarzeń na drogach szybkiego ruchu. Zastosowanie znajdują tutaj sieci neuronowe oraz teoria zbiorów rozmytych.

Tabela 1. Wyniki wskaźników wykrywania dla poszczególnych algorytmów [2].

Nazwa algorytmu	DR (%)	TTD (min)	FAR (%)	Miejsce badania
APID	86	2.50	0.05	Toronto, Boston
DES	92	0.70	1.87	Toronto
ARIMA	100	0.40	1.50	Laboratorium
Bayesian	100	3.90	0	Laboratorium
California	82	0.85	1.73	California, Chicago, Texas
McMaster	68	2.20	0.0018	Minnesota
Sieci neuronowe	89	0.9 - 0.96	0.01 - 0.012	Laboratorium
Zbiory rozmyte	n/a	n/a	do 1.00	n/a
SNID	92	1.10	1.30	n/a
SSID	100	n/a	0.20	Laboratorium
Low Pass Filter	80	4.00	0.3	
TSC #7	67	2.91	0.134	California, Chicago, Texas
TSC #8	68	3.04	0.177	California, Chicago, Texas
Przetwarzanie wideobrazu	90	0.37	3.00	Francja
Telefony komórkowe	38 -100	-	5.00 – 7.4	n/a
Patrole drogowe	17 - 25	-	0 – 5.4	Stany Zjednoczone

4.3. Wykorzystanie sieci neuronowych w algorytmach wykrywania incydentów w miejskiej sieci drogowej.

Wykrywanie incydentów w miejskiej sieci drogowej jest bardziej wymagające niż w przypadku wykrywania incydentu na autostradzie ze względu na następujące czynniki:

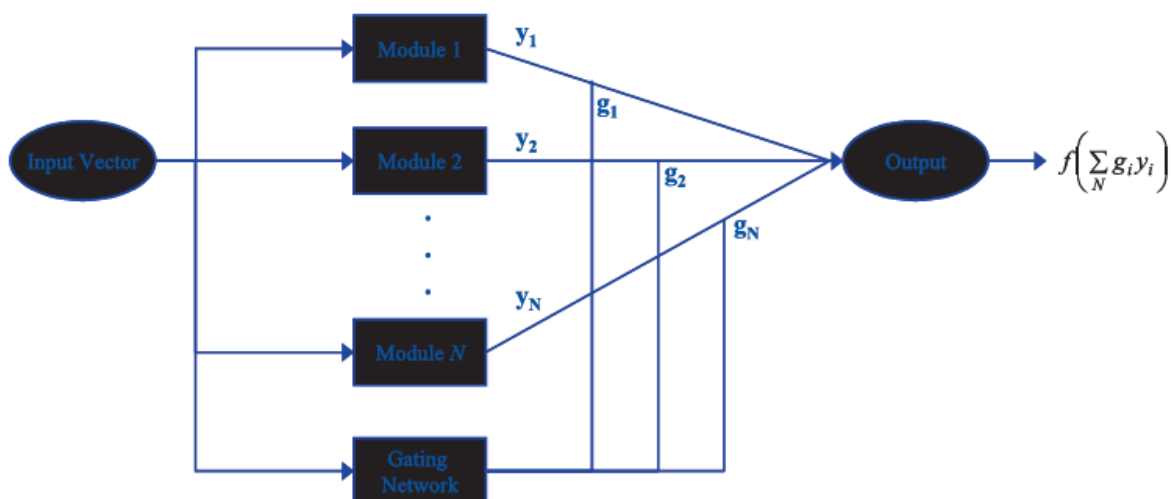
- Autostrady mają ograniczone punkty dostępu, podczas, gdy arterie mają wiele punktów dostępu.
- Możliwość skrętu w lewo lub prawo na skrzyżowaniach, co czyni ruch bardziej nieprzewidywalny.
- Zmiennej i okresowe przerwy w przepływie ruchu spowodowane sygnalizacją świetlną, ustawianie pojazdów w kolejce na skrzyżowaniach
- arterie zwykle działają przy niższych prędkościach, które sprawiają, że zmiana pasa jest łatwiejsza, co może ukrywać skutki incydentu.
- arterie zazwyczaj mają bardziej ograniczoną infrastrukturę do nadzoru niż autostrady [1].

4.3.1. Wielowarstwowe sieci neuronowe oraz sieci modułowe w podejściu H. Dia i K. Thomas.

W badaniach Hussein Dia i Kim Thomas podjęto próbę rozwiązania problemu wykrywania incydentów w arteriach miejskich. Badanie to obejmowało testowanie różnych architektur sieci neuronowych i konfiguracji detektorów. Ze względu na trudności w gromadzeniu danych o incydentach doświadczenie opierało się na danych uzyskanych laboratoryjnie z narzędzia do symulacji ruchu PARAMICS. Badano również wpływ różnych konfiguracji detektorów na skrzyżowaniu. Zostały wykorzystane dwa modele sieci neuronowych:

- Sieć multi-layer feedforward (MLF) – wielowarstwowa sieć neuronowa modyfikująca i kontrolująca proces uczenia z wykorzystaniem jego oczekiwanych rezultatów i efektów.
- Sieć modułowa.

Sieci MLF składają się z warstwy wejściowej, połączonej przez połączenia o odpowiednich wagach do jednej lub więcej warstw ukrytych, które z kolei są połączone poprzez takie same połączenia z warstwą wyjściową. Ukryte warstwy pozwalają sieci dowiedzieć się o nieliniowych zależnościach pomiędzy wejściami i wyjściami. Natomiast sieci modułowe składają się z dwóch lub więcej modułów lub ekspertów (rys. 11). Mimo pozornego skomplikowania, sieci modułowe mogą uczyć się szybciej, dzieląc zadania na mniejsze podzadania. Każdy z modułów działa niezależnie, jednak wszystkie otrzymywały te same dane wejściowe. Również działanie jednego modułu, nie ma wpływu na działanie pozostałych. Jest to szczególnie korzystne w rzeczywistych sytuacjach, w których dane mogą być czasami niedostępne [1].



Rysunek 11. Modułowa sieć neuronowa [1].

Badanie przeprowadzono dla dwóch rodzajów architektur MLF:


- Generalized Feed-Forward (GFF), które mają powiązania, dzięki którym mogą przeskoczyć niektóre warstwy dla szybszego uczenia się,

- Jordan / Elman (JE), które mają dodatkowe elementy przetwarzania (PES), które pamiętają przeszłą aktywność sieci za pomocą konfigurowalnych zanikająco wykładniczo gradientów.

Ponadto przeanalizowano dwa rodzaje sieci modułowych:

- MOD1, który zawierał moduły dwóch ekspertów,
- MOD2, który zawierał moduły czterech ekspertów wraz z zintegrowanym aksonem dostarczającym pamięć dla wejść.

W badaniu wzięto pod uwagę dwie konfiguracje detektorów (fig. 4). Konfiguracja 1: próba potraktowania dróg sieci miejskiej jak autostrady. Korzysta z czujników zainstalowanych poza skrzyżowaniem. Ten typ konfiguracji nie jest aktualnie dostępny dla większości arterii. Konfiguracja 2, jest to standardowa konfiguracja detektorów w miejskiej sieci ulicznej, gdzie pętle znajdują się zarówno przed, jak i za skrzyżowaniami. Jednostki identyfikacyjne pojazdu (VID), wykorzystywane do wykrywania pojazdów były instalowane w tych samych miejscach co detektory pętlowe. Do opracowania standardowego wejścia dla konfiguracji 2, były prowadzone pomiary w miejscach możliwego włączenia się do ruchu [1].



US: Location of upstream detector
VID: Vehicle Identification

DS: Location of downstream detector

Rysunek 12. Konfiguracje detektorów w modelu Dia i Thomasa [1].

Dane generowano dla wielu różnych sytuacji. Zmienne modelu symulacyjnego to:

- Długość odcinka,
- Miejsce zdarzenia incyduentu (przed, na i za skrzyżowaniem),
- Czas trwania incyduentu (15, 30, 60 min),
- Nasilenie incyduentu (liczba zablokowanych pasów ruchu),
- Poziom natężenia (powyżej 600P/h, poniżej 600P/h).

Te różne elementy doprowadziły do powstania 108 incydentów dla każdej konfiguracji. Dane zostały zebrane dla każdego kroku czasowego (20s), niezależnie od fazy sygnału ruchu i zawierały: prędkość, liczbę pojazdów, zajętość (procent czasu kiedy pętla była zajęta) dla wszystkich detektorów na skrzyżowaniu. Zestaw do nauczyciela składa się 50% obserwacji i został użyty do określenia parametrów modelu. 40% obserwacji zostało użyte do oceny wyników wyszkolonego modelu. Dane zostały podzielone identycznie dla obu konfiguracji w celu ułatwienia porównania wyników.

Ogólnie rzecz biorąc wyniki dla konfiguracji 1 detektorów nie były obiecujące. Najlepszy poziom DR uzyskano dla sieci Jordan/Elman i wynosił on 59% przy poziomie FAR=0,5%. Najlepsze wyniki dla konfiguracji 2 uzyskano również dla sieci Jordan/Elman (DR=86%, FAR=0.36%). Wyniki dla konfiguracji 2 detektorów są obiecujące i wskazują na możliwość zbudowania poprawnie funkcjonującego algorytmu wykrywania incydentów w miejskiej sieci ulicznej. Umieszczenie danych o prędkości mogą pomóc w poprawie wydajności sieci neuronowych (DR 90% dla FAR <0,5%). [1].


4.3.2. Podejście S. Khan i S. Ritchie.

Wykorzystanie modularnych algorytmów neuronowych opracowanych przez autorów (Sarosh I. Khan, Stephen G. Ritchie) do detekcji incydentów związanych z blokowaniem pasów ruchu, w szczególności w sieciach miejskich stanowi innowacyjne podejście do problemu wykrywalności nie tylko samych incydentów, ale również ich typu. Porównawcze wykorzystanie danych pozyskanych z terenu oraz danych symulowanych zostało użyte do dokładnego przetestowania działania algorytmu.

W podejściu autorów zastosowano neuronowe klasyfikatory do problemu wykrywania różnego rodzaju incydentów, lub najogólniej do badania problemów operacyjnych na miejskich arteriach drogowych. W tej sekcji autorzy przedstawiają podejście wykorzystujące sieci neuronowe do określenia tzw. ścieżki rozpoznającej/wzorca rozpoznawczego. Wykorzystanie sztucznych sieci neuronowych pozwala na połączenie ze sobą każdego z wielu elementów do przetwarzania. Autorzy skupiają się na wykorzystaniu jednego z typów sieci – tzw. MLF (Multilayer Feedforward – wielowarstwowa sieć ze sprzężeniem zwrotnym). Składa się ona z warstwy wejściowej, z jednej lub wielu nieliniowych warstw ukrytych oraz z warstwy wyjściowej. W procesie stosowane jest zjawisko wstecznej propagacji, które pomaga w uzyskaniu minimalizacji średnich błędów kwadratowych.

Modułowa architektura pozwala na całkowity rozkład i przypisywanie zadań do kilku modułów. Dlatego oddzielne architektury mogą być tak rozwijane, aby każda z nich była w stanie rozwiązać własne zadanie przy wykorzystaniu najlepszej możliwej architektury sieci, a poszczególne moduły lub bloki mogą być łączone, tworząc kompleksowe systemy. Moduły rozkładają problem na dwa lub większą liczbę podsystemów, które działają na wejściach bez komunikowania się ze sobą. Jednostki wejścia które pośredniczą, nie są dopuszczone do zwracania informacji powrotnych do poszczególnych modułów. Modułowa architektura łączy w sobie dwa systemy uczenia, nadzorowane (gating network) i konkurencyjne. Każdy moduł pracuje jako oddzielna sieć wykorzystująca sprzężenie zwrotne, otrzymując jednocześnie te same dane wyjściowe i mająca określoną ilość wyjść. Na koniec wybierany jest moduł posiadający najmniejszy błąd uczenia tzw. zwycięzca [4].

Autorzy, w celu analizy możliwości zastosowania techniki sieci neuronowych do wykrywania problemów eksploatacyjnych dla sieci ulicznych zebrali dane z pętli indukcyjnych zlokalizowanych w określonych miejscach. Dane zostały pozyskane dla dwóch sieci – Anaheim i Los Angeles.



Rysunek 13 Analizowana sieć Los Angeles z lokalizacją pętli indukcyjnych [4].

Dane zebrano w okresie szczytu popołudniowego i szczytu wieczornego, zarówno zawierające, jak i niezawierające problemy operacyjne, takie jak: blokowание pasa ruchu, czy nieprawidłowe działanie detektorów. Długość cyklu zmieniała się od 90 do 120 s. Po zebraniu danych następną czynnością była dokładna charakterystyka ruchu na skrzyżowaniach. Zanotowano wszelkie korelacje i zależności działania poszczególnych pętli i porównanie uzależniające miejsce incydentów od wyników uzyskanych na pętlach. Pod uwagę wzięto również unikalny zbiór danych spowodowany masowymi, szczególnymi wydarzeniami. Testy na jednorodność wariancji-kowariancji cech wejściowych wykazały znaczące różnice wynikające z występowania incydentów lub niewystępowania incydentów [4].

Autorzy skorzystali też z oprogramowania NETSIM do przeprowadzanie mikroskopowej symulacji dla sieci drogowych. Pozwoliło to na przeprowadzenie zindywidualizowanej analizy ruchu na skrzyżowaniach miejskich. Dane wejściowe składały się z m.in.: parametrów dotyczących geometrii sieci drogowej, lokalizacji i typu detektorów, typów skrzyżowania oraz wszelkich możliwych charakterystyk dynamicznych [4].

Aby sklasyfikować warunki incydentów i bez incydentów, dane ruchu i geometrii które najlepiej reprezentowały oba warunki zostały zbadane przez dwa zestawy konfiguracyjne detektorów w różnych warunków potoku ruchu. Dane terenowe i symulowane zostały użyte do rozwinięcia klasyfikatorów przy wykorzystaniu sieci neuronowych. Pod uwagę brano parametry detektorów, w zależności od ich lokalizacji w strumieniach wjeżdżających lub zjeżdżających, analizowane na czasowej przestrzeni długości cykli sygnalizacji świetlnej. Przeanalizowane dwie charakterystyki zawierające różną liczbę cech wejściowych. Jedna z nich składała się z 78 wejść, natomiast druga z 67. Wybór odmiennych podejść pozwolił uzyskać zróżnicowane wyniki dotyczące chociażby procesu uczenia sieci, co z kolei umożliwiało usprawnienie działania całego modelu. Model ma służyć do wykrywania teoretycznie trzech różnych zjawisk: blokowania, zdarzeń specjalnych lub błędów detektora. Dla tego modelu wybrano pojedynczą, binarną cechę wejściową: wyjście „0” identyfikowano jako stan bez incydentu, a wyjście „1” jako stan incydentalny. Ewentualne rozwinięcie modelu miałyby być w stanie rozróżnić już konkretny typ problemów operacyjnych na drodze [4].


Jak w każdym badaniach tego typu autorzy otrzymane wyniki przedstawili przy wykorzystaniu kilku wskaźników, określających skuteczność wykrywalności, czyli DR, FAR, MTTD. Do monitorowania skuteczności procesu uczenia sieci i samego testowaniu użyto wskaźnika klasyfikacji. Zebrane wyniki ze wszystkich prób zostały zestawione i porównane, a następnie opisano najskuteczniejsze z nich. Poniżej przedstawiono wyniki skuteczności wykrywalności ilości incydentów w określonych interwałach czasowych w zależności od stopnia zajętości pasów.

Tabela 2. Wykrywalność w zależności od ilości blokowanych pasów ruchu.

DR using simulated data for the Anaheim network


Incident duration (min)	1 lane blocked		2 lane blocked		3 lane blocked	
	0 PT	1 PT	0 PT	1 PT	0 PT	1 PT
2	0	0	33	0	67	0
4	67	50	67	50	100	67
6	67	67	67	67	100	100
8	67	67	100	67	100	100
12	67	67	100	67	100	100
16	67	67	100	67	100	100
Overall DR	55	53	78	50	94	78

Istotnym wnioskiem badań jest wpływ odpowiedniej konfiguracji algorytmu na dokładność wykrywania, jak i również zależność pomiędzy wskaźnikami DR i FAR, która ukazuje, że wyższy procent wykrywalności skutkuje też zwiększeniem się ilości fałszywych alarmów (rys. 14).



Rysunek 14. Zależność DR od FAR dla wybranych dwóch konfiguracji [4].

Podejście wykorzystujące modułarne sztuczne sieci neuronowe okazało się również dużo skuteczniejsze w porównaniu do zastosowania pojedynczej sieci (rys. 15).




Rysunek 15. Porównanie wykrywalności sieci modułarnej z pojedynczą siecią MLF [4].

Podsumowując swoje badania, autorzy zwracają uwagę na liczne aspekty, które znacznie wpływają na efektywność otrzymanych rezultatów. Stosując różnorodną metodykę porównawczą podkreślają mocne i słabe strony każdego sposobu podejścia do wykrywania incydentów. Podkreślają, że rozwijanie algorytmów modułarnych sieci mogłoby znacznie ułatwić proces wykrywania różnego rodzaju problemów operacyjnych poprzez odpowiednie przypisanie zadania, optymalizując w ten sposób ich wydajność.

5.0. Metodologia analizy.

5.1. Przedstawienie metodologii działania.

Poniżej znajduje się schemat blokowy zastosowanego podejścia do budowy algorytmu wykrywania incydentów na wybranych skrzyżowaniach w Gdyni. Sposób budowy algorytmu powinien być indywidualny dla każdego skrzyżowania, gdyż wiele aspektów ma wpływ na ruch na skrzyżowaniu. Także incydent, w zależności od typu skrzyżowania, może inaczej wpływać na pętle indukcyjne umieszczone w danym układzie. Schemat rozlokowania pętli indukcyjnych, natężenie ruchu na skrzyżowaniu, rozkład ruchu, a także szereg innych czynników determinują budowę algorytmu dostosowanego do danego układu i warunków, które panują na nim.



Rysunek 16. Schemat blokowy podejścia zastosowanego przez autorów.

Tak jak wcześniej wspomniano pierwszym niezbędnym zadaniem do wykonania jest rozpoznanie skrzyżowania. Poznanie rozkładu ruchu na skrzyżowaniu, zasad dotyczących ruchu na skrzyżowaniu, układu pasów, zastosowanej sygnalizacji. Zebrane informacje są niezbędne w dalszym budowaniu algorytmu. Pozwalają na właściwe rozpoznanie zjawisk nieprzewidywanych na skrzyżowaniu, czyli incydentów. Następnym krokiem jest zebranie informacji o incydentach. Zadanie to należy rozumieć nie tylko jako pobranie danych z bazy danych Centrum Zarządzania Ruchem Tristar, ale także przesłanie nagrań z monitoringu na skrzyżowaniu. Sprawdzenie czasu zdarzenia, zaznaczenie długości wpływu incydentu na ruch na skrzyżowaniu. Istotne jest również to, czy dane zdarzenie oddziałuje na wszystkie pętle na skrzyżowaniu, czy tylko na wybrane. Później można przystąpić do dokładniejszej analizy. Należy sprawdzić jak zaobserwowane anomalie przedstawione są za pomocą danych z pętli indukcyjnych. W przypadku niniejszej pracy postanowiono badania parametrów pętli indukcyjnych przeprowadzać w odniesieniu do jednego pełnego cyklu sygnalizacyjnego. Taki podział gwarantuje, że zawsze na każdym wlocie ruch będzie miał podobny charakter. Zastosowany okres pomiarowy wydaje się dla autorów pracy optymalny, aby czas wykrycia zdarzenia był wystarczający. Zastosowanie krótszego okresu czasu mogłoby skutkować tym, że


w danej jednostce pomiarowej ruch na danym detektorze byłby zatrzymany przez sygnał czerwony. Kolejnym powodem dla zastosowania takiego podziału jest to, że obecnie na większości skrzyżowań obowiązuje sygnalizacja zmiennoczasowa. Przez co trudno znaleźć inny podział, który pozwoliłby oddać właściwy obraz ruchu na skrzyżowaniu, który pozwoliłby na przeprowadzenie dalszych analiz, a w dalszej perspektywie wykrycie incydentu.

Następnie należy przeprowadzić konwersję danych do opisanego wyżej modelu. Należy również określić, które dane będą potrzebne w dalszej analizie. Należy sprawdzić, czy wszystkie dane są istotne, czy konieczne są inne dane, które nie są dostarczane do bazy Tristar. Po tak przeprowadzonej analizie należy przeprowadzić proces standaryzacji lub normalizacji danych, aby dane z każdej kolumny były przynajmniej teoretycznie tak samo ważne. Brak przeprowadzenia tego procesu skutkowałby tym, że wartości największe miałyby największy wpływ na realizację algorytmu. Na przykład prędkość (wartość ok. 50) miałaby dużo większy wpływ niż liczba samochodów na pętli w ciągu jednego cyklu (wartość 5). Po przeprowadzeniu tego procesu należy sprawdzić, np. w programie R, czy wprowadzona konfiguracja danych daje podstawy do budowy modelu i otrzymania satysfakcjonujących wyników. Jeżeli wyniki klasyfikacji nie dają dobrych rezultatów konieczna jest przebudowa modelu danych. Jeżeli program klasyfikujący poradzi sobie z rozpoznawaniem cykli incydentalnych, istnieje duże prawdopodobieństwo, że program sieci neuronowych również dobrze rozpozna dane zdarzenie. Aby tak się stało niezbędna jest budowa odpowiedniego nauczyciela. Zbiór ten musi pozwalać sieci neuronowej na rozpoznanie incydentu. Zatem należy przedstawić wzór cyklu incydentalnego. Należy podać różne konfiguracje zdarzeń na skrzyżowaniu, aby sieć była kompleksowa i wykrywała wszystkie typy incydentów. Do nauczyciela należy podać również dane o ruchu normalnym, aby sieć mogła określić w jakim stopniu otrzymany wartości różnią się od ruchu normalnego. Jednak zbudowanie odpowiedniego nauczyciela nie rozwiązuje całości problemu. Należy również dostosować architekturę sieci, tak, aby pozwalała ona na nauczanie się wprowadzonych danych. Jeżeli poziom uczenia jest na zadowalającym poziomie można przystąpić do wprowadzania danych na sieć. W wyniku otrzymuje się prawdopodobieństwo wystąpienia incydentu w danym cyklu.

5.2. Pobieranie danych z bazy TRISTAR.

Do pobrania danych źródłowych niezbędnych do analizy wykorzystano bazy danych systemu TRISTAR. Wszystkie dane z podsystemów spływają do Centralnej Integracyjnej Bazy Danych, a następnie wybrane informacje są agregowane i przechodzą do Hurtowni Danych co przedstawia rysunek 1. Baza Integracyjna i Hurtownia są wykonane w oparciu o MSSQL Serwer 2012. Dzięki temu w przystępny sposób można pobierać dane i dalej obrabiać w miarę indywidualnych potrzeb. W celu pobrania danych z baz wykorzystano wcześniej przygotowane raporty wykonane w SQL Server Reporting Services ze zdefiniowanymi połączeniami do odpowiednich tabel w Integracyjnej Bazie Danych. Dzięki temu po wybraniu interesującej daty można było zapisać dane w plikach CSV.

W przypadku niniejszej pracy wykorzystano dane z dwóch podsystemów systemu TRISTAR. Do analizy wzbudzeń pętli indukcyjnych wykorzystano dane z Systemu Monitorowania i Nadzoru Ruchu Pojazdów, natomiast informację o stanie sygnałów wyświetlanych na sygnalizatorach użyto bazy danych Systemu Sterowania Ruchem Drogowym [9].



Rysunek 17. Współpraca baz danych w systemie TRISTAR [9].

Format danych pozyskanych z systemu składa się z od kilku do kilkunastu kolumn zawierających uporządkowane w czasie informacje dotyczące stanu na pętlach (rys. 18) oraz stanu na sygnalizatorach (rys. 19). Strukturę pozyskanych danych z centrum przedstawiono na poniższych rysunkach wraz z opisem dotyczącym zawartości każdej z poszczególnych kolumn.

1	Czas.UTC	event_date	traffic_station_id	control_point_id	class	direction	speed	length	time_on_control_point	distance_from_previous
2	2015-03-19 11:00:00.5800000	2015-03-19 12:00:00.580	9	7	3	0	42	57	9	419
3	2015-03-19 11:00:01.1400000	2015-03-19 12:00:01.140	9	2	4	0	17	111	34	119
4	2015-03-19 11:00:02.3500000	2015-03-19 12:00:02.350	9	8	2	0	8	35	37	279
5	2015-03-19 11:00:02.5300000	2015-03-19 12:00:02.530	9	10	2	0	33	40	10	219
6	2015-03-19 11:00:03.0100000	2015-03-19 12:00:03.010	9	7	2	0	38	40	9	25
7	2015-03-19 11:00:04.1700000	2015-03-19 12:00:04.170	9	2	2	0	20	48	18	30
8	2015-03-19 11:00:04.7000000	2015-03-19 12:00:04.700	9	8	2	0	17	40	20	24
9	2015-03-19 11:00:04.7100000	2015-03-19 12:00:04.710	9	11	2	0	24	27	12	288
10	2015-03-19 11:00:04.7900000	2015-03-19 12:00:04.790	9	10	2	0	32	45	11	23
11	2015-03-19 11:00:07.8100000	2015-03-19 12:00:07.810	9	8	2	0	19	46	19	31
12	2015-03-19 11:00:07.9100000	2015-03-19 12:00:07.910	9	11	2	0	34	42	10	32
13	2015-03-19 11:00:08.2100000	2015-03-19 12:00:08.210	9	7	2	0	33	34	9	52
14	2015-03-19 11:00:10.5900000	2015-03-19 12:00:10.590	9	10	2	0	24	44	14	57
15	2015-03-19 11:00:11.1700000	2015-03-19 12:00:11.170	9	8	2	0	18	46	19	33
16	2015-03-19 11:00:13.5700000	2015-03-19 12:00:13.570	9	5	2	0	22	37	15	148
17	2015-03-19 11:00:14.5300000	2015-03-19 12:00:14.530	9	8	2	0	17	36	19	34
18	2015-03-19 11:00:16.3500000	2015-03-19 12:00:16.350	9	4	2	0	28	44	12	189
19	2015-03-19 11:00:17.1600000	2015-03-19 12:00:17.160	9	12	2	0	20	44	18	448
20	2015-03-19 11:00:17.9700000	2015-03-19 12:00:17.970	9	8	2	0	12	43	29	34
21	2015-03-19 11:00:19.5600000	2015-03-19 12:00:19.560	9	6	2	0	0	23	623	665
22	2015-03-19 11:00:21.8000000	2015-03-19 12:00:21.800	9	3	2	0	33	43	10	509
23	2015-03-19 11:00:22.8300000	2015-03-19 12:00:22.830	9	6	2	0	10	35	30	33
24	2015-03-19 11:00:23.5700000	2015-03-19 12:00:23.570	9	3	2	0	34	47	10	17
25	2015-03-19 11:00:24.9100000	2015-03-19 12:00:24.910	9	3	2	0	32	42	10	14
26	2015-03-19 11:00:25.2700000	2015-03-19 12:00:25.270	9	6	3	0	18	55	22	24
27	2015-03-19 11:00:25.3500000	2015-03-19 12:00:25.350	9	7	2	0	27	47	13	171
28	2015-03-19 11:00:25.7700000	2015-03-19 12:00:25.770	9	4	2	0	16	27	18	94
29	2015-03-19 11:00:27.1700000	2015-03-19 12:00:27.170	9	3	2	0	33	45	10	22
30	2015-03-19 11:00:27.3700000	2015-03-19 12:00:27.370	9	6	2	0	21	42	16	21
31	2015-03-19 11:00:27.8200000	2015-03-19 12:00:27.820	9	12	2	0	18	42	18	107
32	2015-03-19 11:00:28.1400000	2015-03-19 12:00:28.140	9	8	2	0	10	47	36	102
33	2015-03-19 11:00:28.2700000	2015-03-19 12:00:28.270	9	2	2	0	24	47	15	241
34	2015-03-19 11:00:28.4500000	2015-03-19 12:00:28.450	9	4	2	0	12	35	25	27

Rysunek 18. Format danych dotyczący stanów na pętliach indukcyjnych.

Każda kolumna zawiera unikalne w danym momencie dane na jednej z pętli umiejscowionej na skrzyżowaniu. Opis informacji, które zawierają poszczególne kolumny (wyszczególnione kolumny to najważniejsze składowe dalszej analizy):

- *czas.UTC*: czas wzbudzenia pętli UTC z dokładnością do 0.01 sekundy (w zależności od daty -1 h/-2 h względem czasu polskiego),
- *event_date*: czas zdarzenia z dokładnością do 0.01 sekundy (czas polski)
- *traffic_station_id*: numer stacji pomiarowej,
- *control_point_id*: numer punktu pomiarowego (pętli pomiarowej),
- *class*: klasa pojazdu wzbudzającego pomiar (determinowana wg długości),
- *direction*: kierunek jazdy,
- *speed*: prędkość chwilowa pojazdu (z dokładnością do 1km/h),
- *length*: długość pojazdu (z dokładnością do 0,1 m)
- *time_on_control_point*: czas przebywania pojazdu na punkcie pomiarowym liczony w decysekundach [ds] (z dokładnością do 0,1 sek.),
- *distance_from_previous*: odstęp czasowy od wzbudzenia poprzedniego pojazdu liczony w decysekundach [ds] (z dokładnością do 0,1 sek.),

1	Czas.UTC	CzasStart.UTC	SkrNum	GrupNum	Stan	NumProg	Period	CzasCyklu	SekCyklu
2	2015-03-01 11:00:03.0440000	2015-03-01 11:00:03.000	1150	6	12	2	3	110	4
3	2015-03-01 11:00:05.0440000	2015-03-01 11:00:05.000	1150	7	3	2	85	110	6
4	2015-03-01 11:00:05.0440000	2015-03-01 11:00:05.000	1150	8	3	2	85	110	6
5	2015-03-01 11:00:05.0440000	2015-03-01 11:00:05.000	1150	10	3	2	85	110	6
6	2015-03-01 11:00:05.0440000	2015-03-01 11:00:05.000	1150	9	3	2	85	110	6
7	2015-03-01 11:00:06.0440000	2015-03-01 11:00:06.000	1150	6	3	2	95	110	7
8	2015-03-01 11:00:12.0450000	2015-03-01 11:00:12.000	1150	3	15	2	1	110	13
9	2015-03-01 11:00:12.0450000	2015-03-01 11:00:12.000	1150	11	48	2	31	110	13
10	2015-03-01 11:00:12.0450000	2015-03-01 11:00:12.000	1150	4	15	2	1	110	13
11	2015-03-01 11:00:12.0450000	2015-03-01 11:00:12.000	1150	12	48	2	31	110	13
12	2015-03-01 11:00:13.0480000	2015-03-01 11:00:13.000	1150	4	48	2	9	110	14
13	2015-03-01 11:00:13.0480000	2015-03-01 11:00:13.000	1150	3	48	2	69	110	14
14	2015-03-01 11:00:22.0470000	2015-03-01 11:00:22.000	1150	4	12	2	3	110	23
15	2015-03-01 11:00:25.0470000	2015-03-01 11:00:25.000	1150	4	3	2	199	110	26
16	2015-03-01 11:00:29.0490000	2015-03-01 11:00:29.000	1150	1	15	2	1	110	30
17	2015-03-01 11:00:30.0490000	2015-03-01 11:00:30.000	1150	1	48	2	53	110	31
18	2015-03-01 11:00:31.0500000	2015-03-01 11:00:31.000	1150	13	48	2	55	110	32
19	2015-03-01 11:00:34.0500000	2015-03-01 11:00:34.000	1150	16	48	2	94	110	35
20	2015-03-01 11:00:43.0540000	2015-03-01 11:00:43.000	1150	12	3	2	82	110	44
21	2015-03-01 11:00:43.0540000	2015-03-01 11:00:43.000	1150	11	3	2	82	110	44
22	2015-03-01 11:00:46.0580000	2015-03-01 11:00:46.000	1150	15	15	2	1	110	47
23	2015-03-01 11:00:47.0580000	2015-03-01 11:00:47.000	1150	15	48	2	35	110	48
24	2015-03-01 11:01:22.0780000	2015-03-01 11:01:22.000	1150	15	12	2	3	110	83
25	2015-03-01 11:01:22.0780000	2015-03-01 11:01:22.000	1150	3	12	2	3	110	83
26	2015-03-01 11:01:23.0770000	2015-03-01 11:01:23.000	1150	1	12	2	3	110	84
27	2015-03-01 11:01:25.0770000	2015-03-01 11:01:25.000	1150	3	3	2	39	110	86
28	2015-03-01 11:01:25.0770000	2015-03-01 11:01:25.000	1150	15	3	2	67	110	86
29	2015-03-01 11:01:26.0780000	2015-03-01 11:01:26.000	1150	13	3	2	37	110	87
30	2015-03-01 11:01:26.0780000	2015-03-01 11:01:26.000	1150	1	3	2	39	110	87
31	2015-03-01 11:01:28.0790000	2015-03-01 11:01:28.000	1150	5	15	2	1	110	89
32	2015-03-01 11:01:29.0800000	2015-03-01 11:01:29.000	1150	5	48	2	9	110	90
33	2015-03-01 11:01:30.0790000	2015-03-01 11:01:30.000	1150	8	48	2	27	110	91
34	2015-03-01 11:01:30.0790000	2015-03-01 11:01:30.000	1150	7	48	2	27	110	91
35	2015-03-01 11:01:30.0790000	2015-03-01 11:01:30.000	1150	9	48	2	27	110	91
36	2015-03-01 11:01:30.0790000	2015-03-01 11:01:30.000	1150	10	48	2	27	110	91

Rysunek 19. Format danych dotyczący stanów sygnalizacji.

Każda kolumna zawiera unikalne w danym momencie dane na określonej grupie sygnałowej.

Opis informacji, które zawierają poszczególne kolumny:

- *Czas.UTC*: czas rozpoczęcia nadawania określonego sygnału świetlnego UTC z dokładnością do 0.001 sekundy (w zależności od daty -1 h/-2 h względem czasu polskiego),
- *CzasStart.UTC*: czas rozpoczęcia nadawania określonego sygnału świetlnego UTC zaokrąglony do 1 sekundy (w zależności od daty -1 h/-2 h względem czasu polskiego),
- *SkrNum*: czterocyfrowy numer identyfikacyjny skrzyżowania,
- *GrupNum*: numer grupy sygnałowej,
- *Stan*: stan sygnału:
 - 3 – sygnał czerwony,
 - 12 – sygnał żółty,
 - 15 – sygnał żółty i czerwony,
 - 48 – sygnał zielony
- *NumProg*: numer programu sygnalizacji,
- *Period*: długość wyświetlania określonego sygnału,
- *CzasCyklu*: długość cyklu,
- *SekCyklu*: sekunda cyklu dla danej grupy sygnałowej.

Warto nadmienić, że przykładowy plik z danymi obejmujący cały analizowany dzień (17-18 godzin) składa się z ponad 120 tysięcy wierszy danych pozyskanych z pętli oraz z ponad 25 tysięcy dla danych pozyskanych z sygnalizacji. Taka ilość danych może być problematyczna w analizie jakiegokolwiek większego okresu czasowego, dlatego należało podjąć czynności związane ze skompresowaniem danych. Problematyczne okazało się sprężenie obu tych plików, tak aby w miarę bezproblemowo można było wyodrębnić zakłócenia w ruchu spowodowane rzeczywistym incydem, a nie działaniem światła czerwonego. Dlatego po przeanalizowaniu dostępnej literatury zdecydowano się na „segregację” danych wg cykli działania sygnalizacji.

5.3. Konwersja danych z systemu TRISTAR.

Opisane wyżej dane, aby móc wykorzystać w budowie algorytmu wykrywania incydentów należało odpowiednio przygotować. W związku z tym na potrzeby pracy stworzono bazę danych, do której wprowadzono dane pozyskane z centrum TRISTAR dotyczące ruchu na dwóch badanych skrzyżowaniach:

- Morska – Owsiana
- 10 Lutego – Świętojańska

Baza zawierała dane dotyczące dni, w których miały miejsce incydenty na wybranych skrzyżowaniach:

- 24.07.2014 (Morska-Owsiana)
- 25.07.2014 (Morska-Owsiana)
- 05.05.2015 (Morska-Owsiana)
- 06.03.2015 (10 Lutego – Świętojańska)
- 21.04.2015 (10 Lutego – Świętojańska)
- 13.05.2015 (10 Lutego – Świętojańska)
- 19.05.2015 (10 Lutego – Świętojańska)
- 19.03.2015 (10 Lutego – Świętojańska)

Baza została wgrana na serwer, aby stworzony program mógł przekonwertować dane pozyskane z centrum na format, który pozwoli wprowadzić dane do sieci neuronowej., a także będzie pozwalał na osiągnięcie głównego celu pracy, czyli wykrywania incydentów w miejskiej sieci ulicznej.

Dane zostały zaimportowane na serwer po uprzednim przygotowaniu plików CSV. Baza danych składa się z 4 głównych tabel:

- Lista_skr – tabela zawierająca 4 kolumny
 - Skr_nr – określa nr skrzyżowania,
 - Nazwa – nazwa skrzyżowania,
 - Id – forma 43.2.XX, gdzie XX określa numer stacji pomiarowej na danym skrzyżowaniu,
 - Kamera – pola zawierające informacje o monitoringu skrzyżowania.

skr_nr	nazwa	id	kamera
1010	Morska - Chylonska	43.2.37	TAK
1020	Morska - Owsiana	43.2.35	TAK
1030	Morska - Zbozowa	43.2.34	NIE
1040	Morska - Kcynska	43.2.33	NIE
1050	Morska - Obwodowa	43.2.31	TAK
1060	Morska - Kartuska	43.2.30	TAK
1070	Morska - Nr 303	43.2.29	NIE

Rysunek 20. Tabela bazy danych (Lista_skr).

- Lista_petli – tabela zawierająca 3 kolumny:
 - ID_DT – forma 43.2.X.DTY, gdzie część 43.2.X jest tożsama z kolumną id w tabeli lista_skr, a Y określa numer detektora,
 - Nazwa_det – określa roboczą nazwę detektorów na graficznym planie skrzyżowania,
 - Control_point – identyfikuje numer konkretnego detektora.

ID_DT	nazwa_det	control_point
43.2.1.DT0	P1a'P1a	0
43.2.1.DT1	P1b'P1b	1
43.2.1.DT2	P2a'P2a	2
43.2.1.DT3	P2b'P2b	3
43.2.1.DT4	P3b'P3b	4
43.2.1.DT5	S2a'S2a'	5
43.2.1.DT6	D01D02	6
43.2.1.DT7	D03D04	7
43.2.2.DT0	P1b'P1b	0
43.2.2.DT1	P1c'P1c	1
43.2.2.DT2	P3b'P3b	2
43.2.2.DT3	P3c'P3c	3
43.2.2.DT4	P4b'P4b	4
43.2.2.DT5	P4d'P4d	5
43.2.2.DT6	S1b'S1b'	6
43.2.2.DT7	S1a'S1a'	7
43.2.2.DT8	S2b'S2b'	8

Rysunek 21. Tabela bazy danych (Lista_petli).

- Incydent_XX_XX_XX_sygnal – tabele zawierające 7 kolumn:
 - Czas_startUTC – początkowy czas rozpoczęcia danego cyklu sygnalizacji świetlnej,
 - System – określa system, w którym pracuje dana grupa sygnalizacji świetlnej,
 - Skr_nr – kolumna tożsama z kolumną z tabeli lista_skr,
 - Grupa – numer grupy sygnałowej,
 - Stan – stan sygnalizacji (12-światło żółte, itd.)
 - Nr_program – zastosowany program sygnalizacji na skrzyżowaniu,
 - Dl_cyklu – długość cyklu.

czas_startUTC	system	skr_nr	grupa	stan	nr_program	dl_cyklu
2015-05-05 05:00:57	43	1020	1	12	1	3
2015-05-05 05:02:25	43	1020	1	12	1	3
2015-05-05 05:04:26	43	1020	1	12	1	3
2015-05-05 05:06:08	43	1020	1	12	1	3
2015-05-05 05:07:58	43	1020	1	12	1	3
2015-05-05 05:09:45	43	1020	1	12	1	3
2015-05-05 05:11:32	43	1020	1	12	1	3
2015-05-05 05:13:30	43	1020	1	12	1	3
2015-05-05 05:15:24	43	1020	1	12	1	3
2015-05-05 05:17:54	43	1020	1	12	0	3
2015-05-05 05:19:58	43	1020	1	12	0	3
2015-05-05 05:22:04	43	1020	1	12	6	3
2015-05-05 05:23:58	43	1020	1	12	6	3
2015-05-05 05:26:11	43	1020	1	12	6	3
2015-05-05 05:28:11	43	1020	1	12	6	3
2015-05-05 05:29:52	43	1020	1	12	6	3
2015-05-05 05:32:10	43	1020	1	12	6	3
2015-05-05 05:34:12	43	1020	1	12	6	3
2015-05-05 05:36:11	43	1020	1	12	6	3
2015-05-05 05:38:03	43	1020	1	12	6	3
2015-05-05 05:40:01	43	1020	1	12	6	3

Rysunek 22. Tabela bazy danych (Incydent_XX_XX_XX_sygnal).

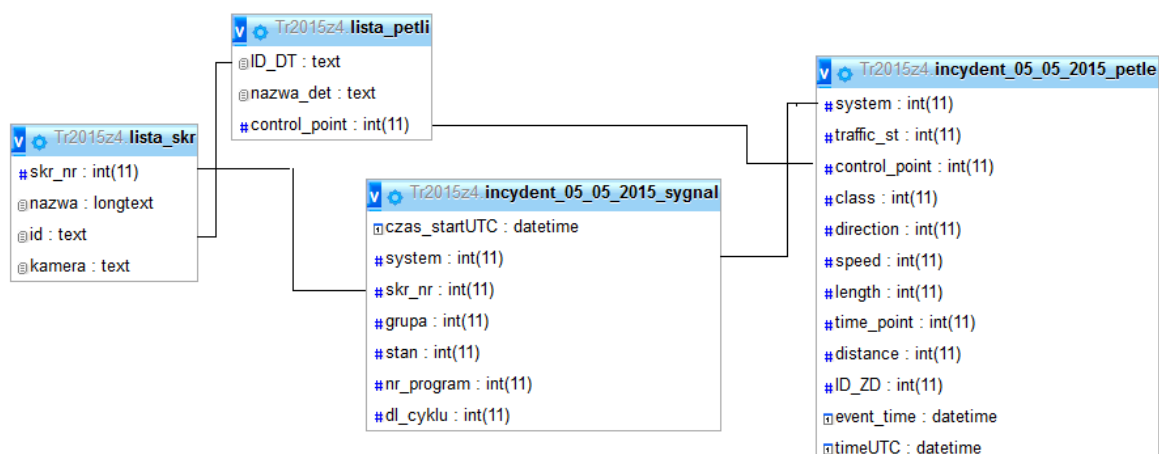
- Incydent_XX_XX_XX_petle – tabele zawierające 12 kolumn:
 - System – tożsame z kolumną z tabeli Incydent_XX_XX_XX_sygnal,
 - Traffic_st – numer stacji pomiarowej dla danego skrzyżowania,
 - Control_point – tożsame z kolumną z tabeli Lista_petli,
 - Class – numer określający klasę pojazdu,

- Direction – kierunek ruchu,
- Speed – prędkość [km/h], jeden z głównych parametrów podlegających pomiarowi i analizie
- Length – długość pojazdu,
- Time_point – czas, który pojazd spędził nad detektorem [ds], jeden z głównych parametrów podlegających pomiarowi i analizie
- Distance – odległość czasowa pomiędzy następnymi pojazdami przejeżdżającymi ponad punktem pomiarowym [ds.], jeden z głównych parametrów podlegających pomiarowi i analizie,
- Event_time – czas wzbudzenia,
- Time UTC – czas UTC

system	traffic_st	control_point	class	direction	speed	length	time_point	distance	event_time	timeUTC
43	35	13	2	0	46	41	7	16	2015-05-05 07:00:00	2015-05-05 05:00:00
43	35	6	4	0	38	115	16	27	2015-05-05 07:00:00	2015-05-05 05:00:00
43	35	14	2	0	48	45	7	23	2015-05-05 07:00:00	2015-05-05 05:00:00
43	35	15	3	0	52	57	7	21	2015-05-05 07:00:01	2015-05-05 05:00:01
43	35	12	2	0	39	38	8	16	2015-05-05 07:00:01	2015-05-05 05:00:01
43	35	5	4	0	27	154	27	37	2015-05-05 07:00:01	2015-05-05 05:00:01
43	35	13	2	0	44	42	8	19	2015-05-05 07:00:02	2015-05-05 05:00:02
43	35	0	4	0	22	72	20	33	2015-05-05 07:00:02	2015-05-05 05:00:02
43	35	15	2	0	53	46	6	17	2015-05-05 07:00:03	2015-05-05 05:00:03
43	35	1	2	0	35	38	9	21	2015-05-05 07:00:03	2015-05-05 05:00:03
43	35	12	2	0	37	45	9	25	2015-05-05 07:00:04	2015-05-05 05:00:04
43	35	0	2	0	27	43	13	20	2015-05-05 07:00:04	2015-05-05 05:00:04
43	35	5	4	0	33	92	15	34	2015-05-05 07:00:05	2015-05-05 05:00:05
43	35	15	2	0	54	40	6	22	2015-05-05 07:00:05	2015-05-05 05:00:05
43	35	1	3	0	33	57	12	22	2015-05-05 07:00:05	2015-05-05 05:00:05
43	35	14	4	0	37	94	14	50	2015-05-05 07:00:05	2015-05-05 05:00:05
43	35	13	2	0	45	40	7	18	2015-05-05 07:00:06	2015-05-05 05:00:06
43	35	12	2	0	29	47	12	23	2015-05-05 07:00:06	2015-05-05 05:00:06
43	35	0	2	0	31	40	11	19	2015-05-05 07:00:06	2015-05-05 05:00:06
43	35	15	2	0	53	40	6	14	2015-05-05 07:00:06	2015-05-05 05:00:06
43	35	14	2	0	41	42	8	11	2015-05-05 07:00:07	2015-05-05 05:00:07

Rysunek 23. Tabela bazy danych (Incident_XX_XX_XX_petle).

Poniżej przedstawiono relacje tabel:



Rysunek 24. Relacje między tabelami.

Do bazy danych zaimplementowano również pliki wynikowe z programu służącego do konwersji danych (program opisany w dalszym rozdziale). Dane te, po przefiltrowaniu przez odpowiedni algorytm (w programie Scilab), będą informować o wystąpieniu potencjalnego incydentu. Liczba kolumn w tej tabeli jest zależna od skrzyżowania, a właściwie liczby pętli indukcyjnych (control_point) na nim. Poniżej przedstawiono strukturę tabeli:

<input type="checkbox"/>	1	ID	int(11)	No	None								
<input type="checkbox"/>	2	od	time	No	None								
<input type="checkbox"/>	3	do	time	No	None								
<input type="checkbox"/>	4	0ile	int(11)	No	None								
<input type="checkbox"/>	5	0v	int(11)	No	None								
<input type="checkbox"/>	6	0t	int(11)	No	None								
<input type="checkbox"/>	7	0d	int(11)	No	None								
<input type="checkbox"/>	8	1ile	int(11)	No	None								
<input type="checkbox"/>	9	1v	int(11)	No	None								
<input type="checkbox"/>	10	1t	int(11)	No	None								
<input type="checkbox"/>	11	1d	int(11)	No	None								
<input type="checkbox"/>	12	2ile	int(11)	No	None								
<input type="checkbox"/>	13	2v	int(11)	No	None								
<input type="checkbox"/>	14	2t	int(11)	No	None								
<input type="checkbox"/>	15	2d	int(11)	No	None								
<input type="checkbox"/>	16	3ile	int(11)	No	None								
<input type="checkbox"/>	17	3v	int(11)	No	None								
<input type="checkbox"/>	18	3t	int(11)	No	None								
<input type="checkbox"/>	19	3d	int(11)	No	None								
<input type="checkbox"/>	20	4ile	int(11)	No	None								

Rysunek 25. Struktura tabeli wynikowej z danymi wprowadzanymi do sieci neuronowej.

- ID – kolumna porządkowa
- Od – Czas początkowy cyklu
- Do – Czas końcowy cyklu
- control_point.ile, control_point.V, control_point.T, control_point.D – średnie dane z danych pętli indukcyjnych w jednym cyklu sygnalizacyjnym.

5.3.1. Program do konwersji danych.

Aby przekonwertować dane z bazy systemu Tristar, stworzono program w języku php/sql. Poniżej przedstawiono najważniejsze fragmenty tego kodu wraz z opisem działania.

Pierwszym krokiem jest połączenie z bazą danych, by program miał możliwość pobierania potrzebnych informacji z niej. Następnie umieszczono polecenie odnalezienie czasu początkowego wszystkich cykli z danego skrzyżowania dla reprezentatywnej grupy sygnałowej (1). Cykle rozpoczynają się sygnałem żółtym (12 w bazie danych). Następne zapytanie dotyczyło liczby pętli na skrzyżowaniu (różnej dla obu skrzyżowań).

```
<?php
$servername = "localhost";
$username = "Tr2015z4";
$password = "2gRX8N";
$dbname = "Tr2015z4";
$conn = new mysqli($servername, $username, $password, $dbname);
if ($conn->connect_error) {die("Problem z baza danych: " . $conn->connect_error);}

$sql = "SELECT (czas_startUTC) AS czasyN FROM `incident_21_04_2015_sygnal`
WHERE incydent_21_04_2015_sygnal.grupa='1' AND
incydent_21_04_2015_sygnal.stan='12'";
$result = $conn->query($sql);

$liczbapetlizapytanie = "SELECT MAX(lista_petli.control_point) as liczba FROM `lista_petli`
WHERE lista_petli.ID_DT LIKE '43.2.13.%'";
$resultLiczbaPetli = $conn->query($liczbapetlizapytanie );
$liczbapetliresult = $resultLiczbaPetli->fetch_assoc();
```

Rysunek 26. Kody programu php/sql dotyczące łączenia z bazą danych, ustalenia czasu początkowego cykli oraz liczby pętli na skrzyżowaniu.

Poniżej przedstawiono kod, który wyciąga z bazy danych potrzebne dane: liczbę pojazdów w danym cyklu na każdej z pętli, średnią prędkość, czas na punktem oraz dystans od poprzedniego pojazdu, które następnie były wysyłane do odpowiednich tabel wynikowych.

```
$prevRow = $result->fetch_assoc();
    $licznik = 1;
    $j = 0;
    while($nextRow = $result->fetch_assoc()) {
        while ($j<$liczbapetli+1 ){
            $sqlDetailed = "SELECT COUNT(speed) AS f1, ".
                "AVG(speed) AS f2, ".
                "AVG(time_point) AS f3, ".
                "AVG(distance) AS f4".
                "FROM incident_21_04_2105_petle ".
                "WHERE incydent_21_04_2015_petle.control_point=$conn->query($liczbapetli)".
                "AND incydent3_petle.timeUTC > ".$prevRow["czasyn"]."".
                "AND incydent3_petle.timeUTC < ".$nextRow["czasyn"]."";


            $resultDetailed = $conn->query($sqlDetailed);
```

Rysunek 27. Pobieranie danych z bazy danych.

5.4. Opis skrzyżowania.

5.4.1. Skrzyżowanie Morska/Owsiana.

Skrzyżowanie znajduje się w terenie zabudowanym i składa się z czterech wlotów. Nadrzędną ulicę stanowi Morska. Na jej zachodnim wlocie wydzielone zostały trzy pasy: relacja prosto-prawo, prosto i lewoskręt. Przeciwny wlot stanowią 4 pasy ruchu: prawoskrętny, 2 pasy jazdy na wprost oraz lewoskręt. Ulice podporządkowane to Chyłońska przechodząca w Owsianą z północy i Owsiana z południa. Wlot północny stanowią trzy wydzielone pasy ruchu: dla skręcających w prawo, dla jadących na wprost oraz dla skręcających w lewo. Południowy wlot przeznaczony jest dla jadących w każdym kierunku. Każdy z wymienionych wcześniej wlotów posiada przejście dla pieszych, ponadto we wschodnio-północnej części przebiega ścieżka rowerowa.




Rysunek 28. Schemat skrzyżowania Morska-Owsiana [19].

Na skrzyżowaniu została zaprojektowana sygnalizacja świetlna składająca się z 19 grup sygnalizacyjnych:

- 6 grup kołowych: 1K1, 2K2, 3K3, 4K4, 5K5, 6K6,
- 4 grupy pieszych: 8P1, 10P2, 11P3, 13P4,
- 2 grupy rowerowe: 9R1, 12R2,
- 4 grupy zielonych strzałek: 14S1, 15S2, 16S3, 17S4,
- 2 grupy migających ostrzeżeń o przejściu dla pieszych: 18O1, 19O2
- 1 grupa rezerwowa: 7rez

Stałoczasowy program sygnalizacji zaprojektowano na $T=110s$. Składa się on z 6 faz. Należy nadmienić, że stałoczasowy program sygnalizacji określono w celu weryfikacji poprawności przyjętych rozwiązań projektowych pod kątem zapewnienia przepustowości i sprawdzenia zawartych w dokumentacji parametrów bezpieczeństwa. Program nie jest w rzeczywistości wykorzystany do sterowania sygnalizacją świetlną.



Rysunek 29. Schemat rozmieszczenia pętli (źr. baza TRISTAR).

Jak widać na powyższym rysunku na obszarze skrzyżowania są strategicznie rozmieszczone pętle indukcyjne różnego typu:

- pętle podwójne (wykorzystywane w późniejszym pracowniu),
- pętle ukośne i prostokątne instalowane tuż przed linią zatrzymania.

W opracowaniu brane pod uwagę będą pętle podwójne, których możliwości pomiarowe pozwalają na uzyskanie określonych parametrów takich jak m.in. prędkość pojazdów lub ilość wzbudzeń pętli. Ich rozmieszczenie kształtuje się w taki sposób, że na pasach wlotowych usytuowane są około 20m przed liniami zatrzymania, natomiast na wylotowych z reguły, w tym wypadku, tuż za przejściami dla pieszych.


Każda z pętli jest odpowiednio zakodowana, w sumie na danym skrzyżowaniu znajduje się ich 16. Ich numeracja w analizowanych danych z systemu to 0-15, natomiast na wszelkich schematach i opracowaniach widnieją ich kody w postaci np.: P2c lub S3a (gdzie P oznacza pętle wlotowe, a S pętle wylotowe, natomiast kolejne cyfry i litera to znaki porządkowe). Wszelkie szczegółowe informacje dotyczące identyfikacji znajdują się w tabeli 2. Dokładna znajomość ich rozmieszczenia jest niezwykle ważnym czynnikiem determinującym rozkład ruchu na skrzyżowaniu oraz wpływa na podjęcie odpowiedniej decyzji w procesie opracowania odpowiedniego algorytmu wykrywania incydentu na danym skrzyżowaniu.

Tabela 3. Identyfikacja numerów pętli na skrzyżowaniu.

Ulica:	NUMER	KOD			
Morska-Owsiana	1020	43.2. <u>35</u>			
KOD ulicy+pętli:	Nazwa pętli:	Numer:	Wlot	Pas	Wylot
43.2.35.DT0	P1hP1e	0	W	pravo/prosto	
43.2.35.DT1	P1gP1d	1	W	prosto	
43.2.35.DT2	P1fP1c	2	W	lewo	
43.2.35.DT3	S3aS3b	3			N
43.2.35.DT4	P2jP2f	4	E	pravo	
43.2.35.DT5	P2iP2e	5	E	prosto	
43.2.35.DT6	P2hP2d	6	E	prosto	
43.2.35.DT7	P2gP2c	7	E	lewo	
43.2.35.DT8	P4jP4h	8	N	pravo/prosto	
43.2.35.DT9	P4kP4i	9	N	lewo	
43.2.35.DT10	P3dP3c	10	S	pravo/prosto/lewo	
43.2.35.DT11	S4aS4b	11			S
43.2.35.DT12	S1aS1c	12			E
43.2.35.DT13	S1bS1d	13			E
43.2.35.DT14	S2aS2c	14			W
43.2.35.DT15	S2bS2d	15			W

5.4.2. Skrzyżowanie 10 lutego/Świętojańska.

Skrzyżowanie znajduje się w terenie zabudowanym w pobliżu skweru Kościuszki. Składa się z czterech wlotów. Nadrzędną ulicę stanowi ul. 10 lutego. Na jej zachodnim wlocie wydzielone zostały trzy pasy: prawoskręt, prosto i lewoskręt. Przeciwległy wlot stanowią dwa pasy ruchu. Pierwszy dla pojazdów skręcających w prawo lub jadących prosto, drugi dla relacji lewo-prosto. Wyloty po obu stronach tej ulicy posiadają dwa pasy ruchu. Ulicą podporządkowaną jest ul. Świętojańska. Wlot północny stanowią dwa wydzielone pasy ruchu: dla skręcających w prawo oraz dla jadących na wprost lub skręcających w lewo. Południowy wlot również składa się z dwóch pasów ruchu: lewoskręt oraz dla relacji pravo-prosto. Na wylotach ul. Świętojańskiej wydzielono po jednym pasie ruchu. Każdy z wymienionych wcześniej wlotów posiada przejście dla pieszych.




Rysunek 30. Skrzyżowanie ul. 10 lutego z ul. Świętojańską [19].

Na skrzyżowaniu została zaprojektowana sygnalizacja świetlna składająca się z 15 grup sygnalizacyjnych:

- 6 grup kołowych: 1K1, 2K2 3K3, 4K4, 5K5, 6K6,
- 5 grup pieszych: 7P1, 7P2, 9P3, 10P4, 11P5
- 4 grupy zielonych strzałek: 12S1, 13S2, 14S3, 15S4,

Dodatkowo ustawiono cztery sygnalizatory migających ostrzeżeń o przejściu dla pieszych: 16O1, 17O2, 18O3, 19O4.

Stałoczasowy program sygnalizacji zaprojektowano na $T=90s$. Składa się on z 6 faz. Należy nadmienić, że stałoczasowy program sygnalizacji określono w celu weryfikacji poprawności przyjętych rozwiązań projektowych pod kątem zapewnienia przepustowości i sprawdzenia zawartych w dokumentacji parametrów bezpieczeństwa. Program nie jest w rzeczywistości wykorzystany do sterowania sygnalizacją świetlną.



Rysunek 31. Rozmieszczenie pętli indukcyjnych na skrzyżowaniu [Tristar].

Powyższy rysunek przedstawia rozmieszczenie pętli podwójnych na badanym skrzyżowaniu. Oprócz, wykorzystywanych w opracowaniu danych, pętli indukcyjnych (zaznaczone czerwonymi numerami) znajdują się również detektory ukośne i prostokątne instalowane przed linią zatrzymania w celu wykrywania obecności pojazdów oczekujących. Pętle podwójne, dzięki zainstalowanym w nich sterownikom, pozwalają na określenie parametrów ruchu pojazdu wzbudzającego daną pętlę podczas przejazdu przez nią. Dane te są następnie przekazywane za pomocą transmisji radiowej/internetowej do Centrum Tristar i zapisywane w bazie danych. Parametry dostępne z poziomu bazy danych to:

- Klasa pojazdu,
- Kierunek jazdy pojazdu,
- Prędkość pojazdu,
- Długość pojazdu,
- Czas nad punktem pomiarowym,
- Dystans od poprzedniego pojazdu,
- Godzina wystąpienia wzbudzenia w czasie UTC.

Pętle na wlotach ulokowane są w odległości ok. 20m od skrzyżowania oraz zaraz za przejściami dla pieszych przy wylotach. W tabeli 4 przedstawiono wszystkie pętle indukcyjne na skrzyżowaniu.

Tabela 4. Pętle indukcyjne na skrzyżowaniu ul. 10 lutego i ul. Świętojańskiej.

Id	Nazwa	Numer kanału
43.2.9.DT0	P1b'P1b	0
43.2.9.DT1	P1d'P1d	1
43.2.9.DT2	P2c'P2c	2
43.2.9.DT3	S3a'S3a	3
43.2.9.DT4	P3b'P3b	4
43.2.9.DT5	P3d'P3d	5
43.2.9.DT6	D01D02	6
43.2.9.DT7	S1aS1a'	7
43.2.9.DT8	P5bP5b'	8
43.2.9.DT9	P6cP6c'	9
43.2.9.DT10	D03D04	10
43.2.9.DT11	D05D06	11
43.2.9.DT12	S2bS2b'	12
43.2.9.DT13	S2aS2a'	13

5.5. Analiza wypadków

5.5.1. Skrzyżowanie Morska/Owsiana.


Na podstawie badań zaistniałych incydentów wpływających na zakłócenia w ruchu miejskim oraz przeglądu nagrań z monitoringu, udało się wyodrębnić trzy zróżnicowane wydarzenia drogowe. Na ich podstawie będzie można przeprowadzić analizę przydatności użycia sieci neuronowych w badaniu wykrywania incydentów. Niestety ich mała ilość wynika albo z braku przydatnych wydarzeń do analizy lub po prostu z braku danych z pętli z danego dnia. Po przeanalizowaniu wszystkich dostępnych wydarzeń – ich ilości oraz przydatności w opracowaniu – na różnych skrzyżowaniach sieci TRISTAR zdecydowano się wybrać dwa najbardziej reprezentatywne, na których zanotowano odpowiednią, minimalną ilość wydarzeń drogowych. Jednym z nich jest skrzyżowanie ulic Morskiej i Owsianej.

Zanotowano trzy incydenty drogowe, a każdy z nich miał mniejszy lub większy wpływ na utrudnienia w ruchu drogowym:

1. Zdarzenie drogowe z dnia 5.05.2015.

Z powodu awarii rury wodociągowej i zalania jezdni zamknięty został pas na ul. Morskiej w kierunku Gdyni. Nieprzejezdna ulica Morska wpłynęła na odczyty parametrów ze stacji pomiarowej TRISTAR na wysokości analizowanego skrzyżowania. Na miejscu zdarzenia

pojawiły się służby porządkowe: straż oraz ekipa PEWiK. Do awarii doszło około godziny 14.30 i utrudnienia w ruchu trwały aż do 17.30. Pomiędzy 15.00, a 17.00 została wyłączona sygnalizacja świetlna. Incydent ten został sklasyfikowany w opracowaniu jako wyraźnie ISTOTNY, ponieważ cały ruch został czasowo wstrzymany.



Rysunek 32. Oznaczone miejsce incydentu z dnia 05.05.

W tabeli 5. znajduje się analiza odczytów incydentalnych (wiersze z anomalią w odczytach parametrów) dla pętli, dla których wypadek miał wpływ na zmienione odczyty. Wiedza dotycząca momentu wydarzeń drogowych jest niezbędna w późniejszym opracowaniu algorytmu wykrywającego.

Tabela 5. Anomalie w odczytach poszczególnych pętli dnia 5.05.2015.

Pętla pomiarowa	Odczyty incydentalne
0	240-280
1	240-280
5	240-295
6	240-295
12	240-280
13	240-280
14	265-297
15	243-297

Odczyty poszczególnych parametrów z wybranej pętli (najlepiej widoczny moment incydentu):



Rysunek 33. Odczyty z pętli nr 13 w dniu 5.05.2015 wraz z oznaczonym momentem incydentu:

a) ilość wzburzeń, b) prędkość, c) czas nad pętlą, d) odstęp czasowy pomiędzy wzburzeniami.




Rysunek 34. Odczyty z pętli nr 0 w dniu 5.05.2015 wraz z oznaczonym momentem incydentu:

a) ilość wzburzeń, b) prędkość, c) czas nad pętlą, d) odstęp czasowy pomiędzy wzburzeniami.

2. Zdarzenie drogowe z dnia 24.07.2014.

Wydarzenie miało miejsce w północno-zachodniej części skrzyżowania. Zablokowane zostały pasy jazdy w kierunku Rumii. Prędkość potoku ruchu znacznie zmalała w tych miejscach, dodatkowo prawy pas wylotowy został zablokowany przez ponad godzinę. Zdarzenie miało też wpływ na częściowe zaburzenie płynności ruchu przeciwnego potoku pojazdów. Niestety nie było dostępne nagranie z tego zdarzenia drogowego.



Rysunek 35. Oznaczone miejsce incydentu z dnia 24.07.2014.

Incydent ten został sklasyfikowany w opracowaniu jako średnio istotny, ponieważ nie spowodował całkowitego wstrzymania ruchu, a jedynie czasowo ograniczył przepustowość skrzyżowania.

W tabeli 6. znajduje się analiza odczytów incydentalnych (wiersze z anomalią w odczytach parametrów) dla pętli, dla których wypadek miał wpływ na zmienione odczyty.

Tabela 6. Anomalie w odczytach poszczególnych pętli dnia 24.07.2014.


Pętla pomiarowa	Odczyty incydentalne
0	182-219
1	178-219
5	177-239
6	177-239
14	179-239
15	179-239
*8	brak odczytów

Odczyty poszczególnych parametrów z wybranej pętli (najlepiej widoczny moment incydentu):



Rysunek 36. Odczyty z pętli nr 5 w dniu 24.07.2014 wraz z oznaczonym momentem incydentu:

a) ilość wzburzeń, b) prędkość, c) czas nad pętlą, d) odstęp czasowy pomiędzy wzburzeniami.




Rysunek 37. Odczyty z pętli nr 14 w dniu 24.07.2014 wraz z oznaczonym momentem incydentu:

a) ilość wzburzeń, b) prędkość, c) czas nad pętlą, d) odstęp czasowy pomiędzy wzburzeniami.

3. Zdarzenie drogowe z dnia 25.07.2014.

Wydarzenie miało miejsce zaraz następnego dnia na tym samym skrzyżowaniu. Tym razem płynność ruchu została zakłócona na pasie w kierunku Gdyni. Charakterystyczny profil parametrów prędkościowych na pętłach znajdujących się na tym kierunku wskazuje na usytuowanie lekkiego zatoru zaraz za pasem do jazdy na wprost. Incydent miał miejsce w godzinach 12.15-13.15. Niestety nie było dostępne nagranie z tego zdarzenia drogowego.



Rysunek 38. Oznaczone miejsce incydentu z dnia 25.07.2014


Incydent ten został sklasyfikowany w opracowaniu jako średnio istotny, ponieważ nie spowodował całkowitego wstrzymania ruchu, a jedynie czasowo ograniczył przepustowość skrzyżowania.

W tabeli 7. znajduje się analiza odczytów incydentalnych (wiersze z anomalią w odczytach parametrów) dla pętli, dla których wypadek miał wpływ na zmienione odczyty.

Tabela 7. Anomalie w odczytach poszczególnych pętli dnia 25.07.2014.

Pętla pomiarowa	Odczyty incydentalne
0	165-203
1	170-205
2	171-204
12	132-255
13	132-255
*8	brak odczytów

Odczyty poszczególnych parametrów z wybranej pętli (najlepiej widoczny moment incydentu):




Rysunek 39. Odczyty z pętli nr 1 w dniu 25.07.2014 wraz z oznaczonym momentem incydentu:

a) ilość wzbudzeń, b) prędkość.

Oprócz wymienionych wcześniej danych z trzech dni „incydentalnych” otrzymano szereg danych z dni, w których nie zanotowano żadnego zdarzenia drogowego – 4.05.2015, 6.05.2015, 7.05.2015, 11.05.2015, 12.05.2015, 14.05.2015, 19.05.2015, 21.05.2015. W celu rozszerzenia ewentualnych możliwości podczas analizy najbardziej odpowiedniego algorytmu wykrywania, wprowadzono dodatkowo dwie symulacje incydentów w dniach:

- 11.05.2015 (incydent średnio istotny odpowiadający danym z dni 24.07 i 25.07 o podobnej charakterystyce) .

Zdarzenie wprowadzono na pasach ruchu w kierunku Rumii. Istotnie zmniejszono prędkość wzdłuż tego kierunku, jednocześnie nie ingerując w odczyty na innych wlotach i wylotach. Zdarzenie zasymulowano tak, aby jego charakterystyka była jak najbardziej zbliżona do incydentów z dni 24.07 oraz 25.07, gdzie głównym powodem było jedynie czasowe zmniejszenie prędkości ruchu, niepowodujące jednak poważniejszych zatorów potoku pojazdów.




Rysunek 40 Oznaczone miejsce symulacji incydentu z dnia 11.05.2015

W tabeli 8. znajduje się analiza odczytów incydentalnych (wiersze z anomalią w odczytach parametrów) dla pętli, dla których wypadek miał wpływ na zmienione odczyty.

Tabela 8. Anomalie w odczytach poszczególnych pętli dnia 11.05.2015.

Pętla pomiarowa	Odczyty incydentalne
5	145-174
6	145-174
14	145-174
15	145-174


Odczyty poszczególnych parametrów z wybranej pętli (najlepiej widoczny moment incydentu):



Rysunek 41. Odczyty z pętli nr 5 w dniu 11.05.2015 wraz z oznaczonym momentem incydentu:
 a) ilość wzbudzeń, b) prędkość.

- 12.05.2015 (incydent istotny odpowiadający danym z dnia 5.05. o podobnej charakterystyce w ten sam dzień tygodnia).

Zdarzenie wprowadzono na pasach ruchu w kierunku Gdyni. Zmniejszono zarówno prędkość, jak i ilość wzbudzeń pętli przez przejeżdżające pojazdy wzdłuż tego kierunku. Zablokowany został całkowicie ruch na jednym z pasów w celu zbliżenia charakterystyki incydentu do danych z dnia 5.05. Na pozostałych pasach miejsca zdarzenia znacząco został ograniczony ruch.



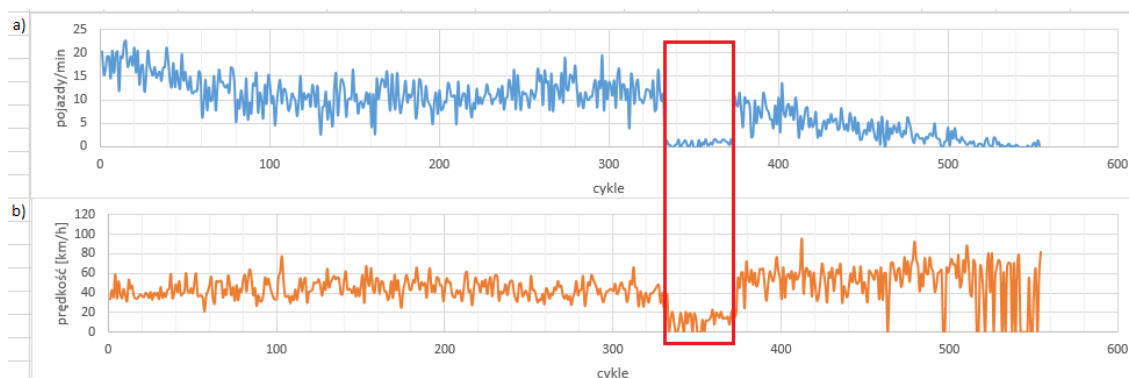
Rysunek 42. Oznaczone miejsce symulacji incydentu z dnia 12.05.2015.

W tabeli 9. znajduje się analiza odczytów incydentalnych (wiersze z anomalią w odczytach parametrów) dla pętli, dla których wypadek miał wpływ na zmienione odczyty.

Tabela 9. Anomalie w odczytach poszczególnych pętli dnia 11.05.2015.

Pętla pomiarowa	Odczyty incydentalne
0	333-373
1	333-373
12	333-373
13	333-373

Odczyty poszczególnych parametrów z wybranej pętli (najlepiej widoczny moment incydentu):



Rysunek 43. Odczyty z pętli nr 1 w dniu 12.05.2015 wraz z oznaczonym momentem incydentu:


a) ilość wzbudzeń, b) prędkość.

5.5.2. Skrzyżowanie 10 lutego/Świętojańska.


Na skrzyżowaniu ul. 10 lutego oraz ul. Świętojańskiej przeanalizowano dane z pętli indukcyjnych z czterech dni, w których wystąpiły incydenty: 21.04.2015, 13.05.2015, 19.05.2015 oraz 6.03.2015. Dodatkowo przeanalizowano dane z dni, w których nie zauważono na nagraniach z monitoringu miejskiego zdarzeń incydentalnych. Są to dni: 6.05.2015- 21.05.2015 (z wyłączeniem dni z incydentami). Udało się również uzyskać dane z incydemem 19.03.2015, jednak z powodu awarii sprzętowej dane te obejmują tylko czas zdarzenia oraz czas ok. godziny przed i po zdarzeniu. Poniżej przedstawiono strukturę i rodzaj każdego z incydentów.

1. Incydent 21.04.2015.

Z powodu przemarszu został zablokowany wylot na ulicy Świętojańskiej, w wyniku czego wzbudzenia na pętli nr. 3 zostały ograniczone. Ruch na pozostałych wlotach/wylotach skrzyżowania odbywał się normalnie. Przeanalizowano dane dla wszystkich pętli indukcyjnych (ilość wzbudzeń, średnia prędkość, czas nad punktem pomiarowym, dystans od poprzedniego pojazdu), które przedstawiono na odpowiednich wykresach. Z uwagi na dużą liczbę wykresów przedstawiono tylko przykładowy wykres, który pokazuje zmiany na pętli indukcyjnej w czasie incydentu.



Rysunek 44. Reprezentacja graficzna incydentu 21.04.2015.




Rysunek 45. Odczyty z pętli nr 3 w dniu 21.04.2015 wraz z oznaczonym momentem incydentu:
a) ilość wzbudzeń, b) prędkość, c) czas nad pętlą, d) odstęp czasowy pomiędzy wzbudzeniami.


Na wykresach zależności łatwo zauważyć anomalie w cyklach 62-120, które odpowiadają godzinom zajęcia pasa, czyli 8:30-10:00. Niestety na pozostałych pętlach nie zauważono zmian świadczących o wpływie incydentu na pozostałe pętle.

2. Incydent 13.05.2015.

Tego dnia odbywał się przemarsz w wyniku czego wyłączono z ruchu kołowego południowy wlot ul. Świętojańskiej. W wyniku nagromadzenia osób chwilowo wstrzymano został ruch również na wylocie. Spowodowało to zaburzenia w odczytach z pętli 8 i 9 w cyklach 111-125 oraz na pętli 3 w cyklach 120-124. Wstrzymanie ruchu występowało w godzinach 9:45-10:05.



Rysunek 46. Incydent 13.05.2015.




Rysunek 47. Odczyty z pętli nr 8 w dniu 13.05.2015 wraz z oznaczonym momentem incydentu:


a) ilość wzbudzeń, b) prędkość.

3. Incydent 19.05.2015.


O godz. 11.25 miało miejsce zderzenie dwóch aut, w wyniku czego nastąpiły zaburzenia w płynności ruchu na skrzyżowaniu. W wyniku tego zdarzenia wzbudzenia na pętli 10 ustały, natomiast wzbudzenia na pętli 11 uległy zwiększeniu przy spadku średniej prędkości na tej pętli. Zaburzenia odpowiadają cyklom 178-204. Stopniowo powiększający się zator na północnym prawoskręcie spowodował zmniejszenie średniej prędkości na pętli 6 oraz zmniejszenie ilości wzbudzeń w cyklach 196-204.




Rysunek 48. Incydent 19.05.2015.



Rysunek 49. Odczyty z pętli nr 10 w dniu 19.05.2015 wraz z oznaczonym momentem incydentu:
a) ilość wzbudzeń, b) prędkość.




Rysunek 50. Odczyty z pętli nr 11 w dniu 19.05.2015 wraz z oznaczonym momentem incydentu:
a) ilość wzbudzeń, b) prędkość.




Rysunek 51. Odczyty z pętli nr 6 w dniu 19.05.2015 wraz z oznaczonym momentem incydentu:
a) ilość wzbudzeń, b) prędkość.

4. Incydent 6.03.2015.

W wyniku najechania na tył pojazdu nastąpiło zablokowanie pasa do jazdy na wprost na wlocie zachodnim. Zdarzenie miało miejsce o godzinie 7:30 i zakłócenia pozostawały przez ok. 20minut. Odpowiada to danym z cykli 16-38. Zdarzenie wystąpiło w godzinach porannych w związku z tym nie zanotowano większych zmian w danych z pętli poza spadkiem liczby wzbudzeń na pętli 1. Liczba wzbudzeń na pętli 0 oraz 2 jest wyższa niż w przypadku tego samego okresu bez incydentu na pętli 1.




Rysunek 52. Incydent 6.03.2015.



Rysunek 53. Odczyty z pętli nr 1 w dniu 6.03.2015 wraz z oznaczonym momentem incydentu:
a) ilość wzbudzeń, b) prędkość.

5. Incydent 19.03.2015.



Rysunek 54. Incydent 19.03.2015.

Trolejbus jadący od zachodniego wlotu prosto zderzył się z samochodem skręcającym w lewo z wlotu wschodniego. Anomalie w odczytach na poszczególnych pętlach przedstawia tabela.

Incydent jest widoczny praktycznie na całym skrzyżowaniu, na zachodnim wlocie, gdzie wzbudzenia ustaly (pętla 12, 13, 4, 5), natomiast na pozostałych pętlach można zauważyć zmniejszenie średniej prędkości.

W oparciu o powyższe wypadki oraz dane z dni bezwypadkowe zasymulowano wypadek odpowiadający zamknięciu północnego wylotu (pętla 7).

Tabela 10. Anomalie na pętlach indukcyjnych podczas wypadku 19.03.2015.

Pętla indukcyjna	Występujące anomalie
0	Brak
1	Spadek średnich prędkości w cyklach 84-117
2	Brak
3	Minimalny spadek średniej prędkości w cyklach 85-104
4	Znaczne zmniejszenie liczby wzbudzeń w cyklach 83-94, później całkowite zatrzymanie wzbudzeń do cyklu 117
5	Znaczne zmniejszenie liczby wzbudzeń w cyklach 83-94, później całkowite zatrzymanie wzbudzeń do cyklu 117
6	Spadek średnich prędkości w cyklach 81-117
7	Spadek średnich prędkości w cyklach 79-117
8	Zmniejszenie liczby wzbudzeń oraz średnich prędkości w cyklach 85-117
9	Spadek średnich prędkości
10	Brak
11	Brak
12	Całkowite zatrzymanie liczby wzbudzeń w cyklach 79-117
13	Występują tylko pojedyncze wzbudzenia co kilka cykli z niską prędkością

5.5. Analiza w programie R

Program R w oparciu o wprowadzone dane ustala średnie clusters dla każdej kolumny (poniższy rysunek). Następnie liczona jest wartość sumy kwadratów danej clusters. Przypisanie do właściwej clusters następuje poprzez znalezienie najmniejszej różnicy pomiędzy wartościami SUM_i (wzór 5.1.) danego wiersza, a wartościami wiersza cluster means..

```
Cluster means:
1  1.2604730 -1.0302548 -1.34841867 -1.2290718 -0.47597751 -1.2278556 -0.92295016
2  1.5404392 -0.8613416 -1.02509652 -0.8256010 0.07839629 -1.0157272 0.34442303
3 -0.8495079 0.3989530 0.05969126 0.9734931 -0.12705786 0.5292320 -0.34559566
4 -0.2249739 0.4997282 0.26282664 0.3924700 -0.12742986 0.3638159 0.07775109
5  1.4949163 -0.9129652 -0.81669537 -0.8276196 0.48468059 -1.2571165 -0.78097603
6 -0.7218931 0.2992051 0.28243728 0.2978534 -0.06996233 0.6305752 0.03611818
7  0.3768193 -0.3849313 0.10724815 -0.2769062 0.32274873 -0.5017663 0.48202892
```

Rysunek 55. Cluster means.

$$SUM_i = \sum_{n=1}^m x_n^2 \quad \text{Wzór 5.1.}$$

gdzie:

i – numer clusters

m – liczba kolumn

x_n – wartość cluster means

5.5.1. Skrzyżowanie Morska/Owsiana.

Dane z każdego z opisanych wypadków zostały poddane analizie w oprogramowaniu „R” w celu oszacowania ich możliwości porównawczych w procesie tworzenia skutecznego algorytmu wykrywającego. Wyniki okazały się również pomocne w określeniu tego, w jakim stopniu wybrane pętle, jak i również określone parametry wpływają na wymagane rezultaty. Badania zostały podzielone na kilka etapów:

Etap 1.

Kompleksowe uwzględnienie wszystkich pętli wraz ze wszystkimi parametrami pomiarowymi (ilość wzbudzeń, prędkość, czas na pętli, odległość czasowa pomiędzy kolejnymi wzbudzeniami) znajdujących się na skrzyżowaniu.

Etap 2.

Kompleksowe uwzględnienie wszystkich pętli wraz z dwoma głównymi parametrami pomiarowymi (ilość wzbudzeń i prędkość) znajdujących się na skrzyżowaniu.

Etap 3.

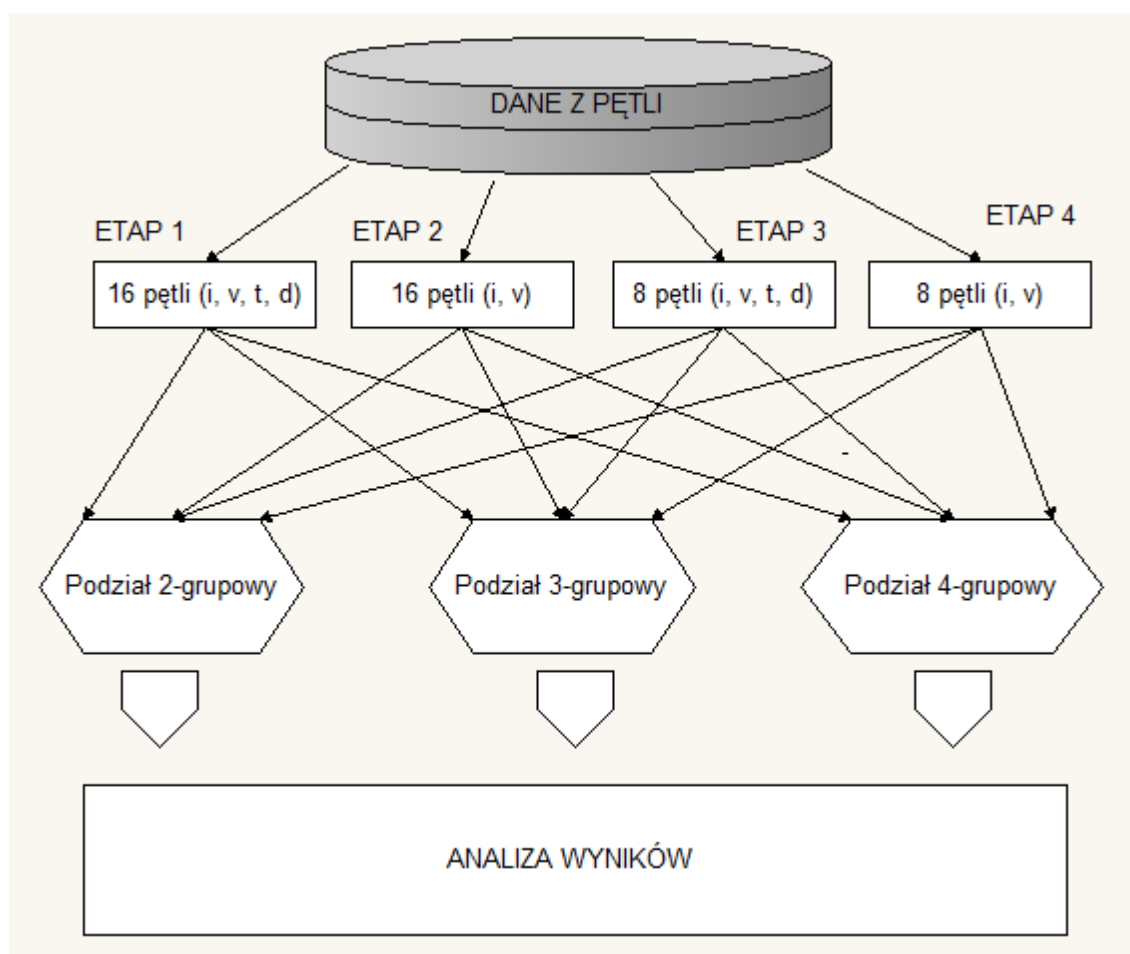
Uwzględnienie najistotniejszych pętli (0, 1, 5, 6, 12, 13, 14, 15) wraz ze wszystkimi parametrami pomiarowymi (ilość wzbudzeń, prędkość, czas na pętli, odległość czasowa pomiędzy kolejnymi wzbudzeniami) znajdujących się na skrzyżowaniu.

Etap 4.

Uwzględnienie najistotniejszych pętli (0, 1, 5, 6, 12, 13, 14, 15) wraz z dwoma głównymi parametrami pomiarowymi (ilość wzbudzeń i prędkość) znajdujących się na skrzyżowaniu.

Testowi poddano wszystkie „incydentalne” dni w celu wyodrębnienia tzw. grup (clusters), różniących się od siebie. Przeprowadzono trzykrotne badanie z różną ilością grupowania (2-3-4 cluster means) poszczególnych cykli, aby dokładniej sprawdzić, w których miejscach wyróżnić można anomalię ruchu na skrzyżowaniu (incydent, ewentualnie zmniejszony ruch wieczorny).

Należy podkreślić, że sam „umowny” podział na konkretną ilość grup jest jedynie niezbędny w celu określenia, w jaki sposób w dalszych badaniach sieć poradzi sobie z analizą danych. Im bardziej uwydatnione będą cykle incydentalne tym lepiej dla późniejszych badań już w procesie uczenia na sieciach.



Rysunek 56 Uproszczony schemat dotyczący sposobu analizy danych w środowisku R.

- Dzień 24.07.

Analiza wyników w etapie pierwszym:

- dla podziału dwugrupowego nie ma możliwości odzyskania momentu incydentu, ruch można podzielić jedynie na dzienny oraz wieczorny,
- dla podziału trójgrupowego, można wyodrębnić cykle związane z incydem oraz cykle bez zdarzeń drogowych - dzienne i wieczorne,
- dla podziału czterogrupowego uwidocznił się podział na normalne warunki ruchu: dzienne (nr 4), moment incydentu drogowego (nr 1), ruch późno-popołudniowy i wieczorny (nr 3 i nr 2).

Clustering vector:

```
[1] 4 3 3 3 3 4 4 4 3 3 4 4 3 4 4 4 4 4 4 4 4 4 4 4 4 4 3 4 4 4 4 4 4 4 4 4 3 3 3 4
[38] 4 3 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 3 4 4 4 4 4 4 4 4 4 4 3 4 4
[75] 3 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[112] 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[149] 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[186] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
[223] 1 4 4 4 4 4 4 4 4 4 1 1 1 1 1 1 1 1 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[260] 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[297] 3 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[334] 4 4 4 4 4 4 4 4 4 4 4 4 3 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[371] 4 4 4 4 4 4 4 4 3 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[408] 4 4 4 4 3 3 4 3 3 4 3 4 4 4 4 4 4 4 3 3 4 3 3 3 3 3 3 4 3 4 3 4 3 4 4 4 3 3 3 3 3 3
[445] 4 3 3 4 3 3 3 3 3 3 3 3 4 3 3 3 3 3 3 3 4 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
[482] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
[519] 3 3 3 3 3 3 3 3 2 3 3 3 3 3 3 3 2 2 2 3 3 3 3 2 2 2 3 2 2 2 2 2 2 2 2 2 2 2 2 2
[556] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 3 2
```

Rysunek 61. Wektor klastrowy 4-grupowy - dzień 24.07, etap 1.

Analiza wyników w etapie drugim:

- dla podziału dwugrupowego zmniejszenie ilości parametrów nie polepszyło wykrycia, ruch można podzielić jedynie na dzienny oraz wieczorny,
- dla podziału trójgrupowego zmniejszenie ilości parametrów skutkowało podobnymi wynikami jak w etapie pierwszym – podział: incydent/brak incydentu w dzień/brak incydentu wieczorem,
- dla podziału czterogrupowego zmniejszenie ilości parametrów uwidoczniło podział na normalne, aczkolwiek niejednostajne warunki ruchu: dzienne (nr 2 i 4), moment incydentu drogowego (nr 3) i ruch wieczorny (nr 1).

Clustering vector:

```
[1] 2 4 1 4 4 3 2 2 4 1 2 4 4 2 2 2 2 2 2 2 2 4 2 2 4 2 2 4 2 2 2 2 2 4 4 1 4
[38] 4 4 2 2 4 2 4 2 2 2 2 4 4 2 2 4 4 4 2 2 4 4 4 2 2 4 2 2 2 2 2 4 2 4 4 4 4 4 2 2
[75] 4 2 3 4 4 2 2 2 4 2 2 2 2 2 2 4 4 4 2 4 4 2 2 2 4 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[112] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[149] 2 2 2 4 2 2 2 2 2 2 2 2 2 2 2 2 2 2 4 2 2 2 4 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[186] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
[223] 3 2 2 4 2 2 2 2 2 2 3 3 2 3 3 3 3 3 2 2 2 2 2 4 4 2 2 4 4 4 4 2 2 2 4 4 2 2 4 2 2
[260] 4 2 2 2 4 4 4 4 2 2 2 4 2 2 2 4 2 2 2 2 2 2 2 2 2 2 2 2 2 4 4 4 4 2 2 2 4 4 2 2 2
[297] 4 2 2 4 2 2 2 4 2 2 4 4 2 2 4 4 2 4 2 2 2 2 2 2 2 2 2 2 4 2 4 2 2 2 4 2 4 4 2 4
[334] 4 2 2 4 2 4 2 2 2 4 2 2 2 2 4 2 2 2 4 4 4 4 4 4 2 2 4 4 4 4 2 2 4 4 4 2 2 4 4 2 4
[371] 4 4 2 4 4 4 4 4 2 2 4 2 2 2 4 4 4 2 2 4 4 4 2 4 4 4 2 4 4 4 4 4 4 4 4 4 4 4 4 4
[408] 4 2 4 2 4 4 4 1 4 4 4 2 2 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[445] 2 4 4 4 4 4 1 4 4 1 4 4 1 4 4 1 4 4 1 4 4 2 1 4 1 4 4 4 1 4 4 4 1 4 4 4 4 4 1 4 4
[482] 4 1 1 4 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
[519] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
[556] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
```

Rysunek 62. Wektor klastrowy 4-grupowy - dzień 24.07, etap 2.

Analiza wyników w etapie trzecim:

- a) dla podziału dwugrupowego zmniejszenie ilości pętli poskutkowało podobnymi wynikami jak w etapach poprzednich: podział na dzień i wieczór,
- b) dla podziału trójgrupowego zmniejszenie ilości pętli poskutkowało podobnymi wynikami jak w etapach poprzednich– podział: incydent/brak incydentu w dzień/brak incydentu wieczorem,
- c) dla podziału czterogrupowego zmniejszenie ilości pętli poskutkowało podobnymi wynikami jak w etapie pierwszym: normalne warunki ruchu (nr 3), moment incydentu drogowego (nr 4), ruch późno-popołudniowy i wieczorny (nr 2 i 1).

Clustering vector:

```
[1] 3 2 2 2 2 3 3 3 2 2 3 3 2 3 3 3 3 3 3 3 3 3 2 3 3 2 3 2 3 3 3 3 3 3 2 2
[38] 3 2 3 3 2 3 3 3 3 3 2 3 3 3 3 3 2 3 2 3 2 3 3 3 3 3 3 2 3 2 3 3 3 3 3 3
[75] 2 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2 3 3 3 3 3 3 3 3 3 3 3
[112] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
[149] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
[186] 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 3
[223] 4 3 3 3 3 3 3 3 3 3 4 4 4 4 4 4 4 4 3 3 3 3 3 3 3 3 3 3 2 2 2 3 3 3 3 3 2
[260] 2 3 3 3 3 3 3 3 3 3 3 3 2 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
[297] 2 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2
[334] 3 3 3 2 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2 3 2 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
[371] 3 3 3 2 2 3 3 2 3 3 2 3 3 3 2 2 2 3 3 3 3 2 3 3 3 3 2 3 3 2 3 3 2 2 3 3
[408] 2 3 3 2 2 2 2 2 2 3 3 3 3 2 2 3 2 2 2 2 2 2 2 2 3 2 2 2 2 3 3 2 2 3 2 2
[445] 3 2 2 3 2 2 2 2 2 2 2 2 2 3 2 2 2 2 2 2 2 2 3 2 2 2 2 2 2 2 2 2 2 2 2 2
[482] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[519] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[556] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 2 1 1 1 2 2 2 1 1 1 2 1 1 1 1 1 1 1 1 1 1 1 1
```

Rysunek 63. Wektor klastrowy 4-grupowo - dzień 24.07, etap 3.

Analiza wyników w etapie czwartym:

- a) dla podziału dwugrupowego zmniejszenie ilości pętli i parametrów poskutkowało podobnymi wynikami jak w etapach poprzednich: podział na dzień i wieczór
- b) dla podziału trójgrupowego zmniejszenie ilości pętli i parametrów, poskutkowało podobnymi wynikami jak w etapach poprzednich: incydent - brak incydentu dzień - brak incydentu wieczór
- c) dla podziału czterogrupowego zmniejszenie ilości pętli i parametrów poskutkowało podobnymi wynikami jak w etapie drugim: normalne, aczkolwiek niejednostajne warunki ruchu (nr 1 i 3), moment incydentu drogowego (nr 4) i ruch wieczorny (nr 2).

Clustering vector:

```
[1] 3 1 2 1 1 4 3 3 1 1 3 1 1 3 3 3 3 3 3 3 1 3 3 1 3 1 1 3 1 3 3 3 3 1 1 1 1
[38] 1 1 3 3 1 3 3 3 3 3 3 1 3 3 3 1 3 1 1 1 1 1 3 3 3 3 1 3 1 1 1 1 1 3 1 3 3
[75] 1 3 3 1 1 1 3 3 1 3 3 3 3 3 3 3 1 1 1 1 3 1 1 3 3 3 1 3 1 3 3 3 3 3 3 3 3
[112] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
[149] 3 3 3 1 3 3 3 4 3 3 3 3 3 3 3 3 3 3 1 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
[186] 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 1
[223] 4 3 3 1 3 3 3 3 3 4 4 4 4 4 4 4 4 4 3 3 3 3 3 1 1 3 3 1 1 1 1 3 3 3 1 1 3 1
[260] 1 3 3 3 3 1 1 1 1 3 3 3 1 3 1 1 3 3 3 3 1 3 3 3 3 3 3 3 3 3 3 1 3 1 3 3 3 3
[297] 1 3 3 1 3 3 3 1 3 3 3 1 1 3 3 1 3 1 1 3 3 3 3 3 3 3 3 3 1 3 1 3 1 3 1 1 3 1
[334] 1 3 3 1 3 1 3 3 3 1 3 3 1 3 1 3 3 3 1 1 1 1 1 3 3 1 1 1 1 3 3 1 1 1 1 1 1 1
[371] 1 1 1 1 1 1 1 1 1 3 1 1 3 3 3 1 1 1 3 3 1 3 1 3 1 3 1 1 1 1 1 1 1 1 1 1 1 1
[408] 1 1 1 1 1 1 1 1 2 1 1 1 3 3 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 2 1
[445] 3 1 1 1 2 1 1 2 1 2 1 1 1 2 1 1 1 1 1 1 1 1 1 2 1 1 2 2 1 1 1 1 1 2 2 1 1
[482] 1 2 1 2 2 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[519] 2 2 2 2 2 2 2 2 2 2 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[556] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
```

Rysunek 64. Wektor klastrowy 4-grupowo - dzień 24.07, etap 4.


```

Clustering vector:
[1] 4 4 4 4 4 4 4 2 4 4 4 4 4 4 4 2 1 4 1 1 1 4 1 1 2 2 1 4 1 1 1 4 4 4 2
[38] 2 4 4 4 4 1 2 2 1 1 1 1 1 1 4 4 1 2 1 4 4 4 1 1 1 4 4 4 2 4 1 1 4 4 1 2
[75] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 2 1 1 1 1 1 1 1 2 1 1 1 1 4 1 4 4 1 1 2 1 1 1
[112] 4 2 1 2 2 2 1 2 1 1 1 1 1 1 1 1 1 2 1 1 2 2 1 1 1 2 1 1 2 4 2 2 1 2 2 1 1
[149] 2 2 2 2 2 2 2 1 2 2 2 2 2 2 2 2 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[186] 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[223] 2 2 2 2 2 2 2 2 2 2 2 2 2 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[260] 1 4 1 4 1 4 1 2 2 1 1 4 1 2 1 4 1 2 4 1 4 1 2 2 4 4 1 1 1 1 4 4 1 1 1 1 4
[297] 4 1 2 4 4 4 4 1 1 2 1 1 1 4 2 1 2 1 1 1 4 1 1 4 4 1 4 4 1 4 2 1 4 4 4 1 2 1 1 1
[334] 1 4 2 4 1 1 4 1 4 2 1 4 1 1 1 1 1 4 4 4 4 1 4 2 4 2 4 1 1 4 1 4 2 1 2 4 1
[371] 4 4 2 4 4 4 4 2 4 4 4 1 1 4 4 1 4 1 4 4 1 1 2 4 4 1 2 1 4 4 1 4 3 1 2
[408] 4 4 4 4 1 4 4 4 3 1 4 1 4 4 4 2 4 4 4 4 4 2 4 4 1 4 4 4 1 1 4 4 3 1 4 4 4
[445] 4 4 4 4 4 1 1 4 4 4 1 3 4 4 1 3 3 4 4 4 4 4 4 4 4 4 3 4 4 4 3 4 4 4 3 4
[482] 4 3 4 4 4 3 4 3 4 4 3 3 3 3 4 3 3 4 3 3 4 3 4 3 4 3 4 1 4 3 3 3 4 4 3 3 4 3
[519] 3 3 3 3 3 4 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
[556] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3

```

Rysunek 66. Wektor klastujący 4-grupowo - dzień 25.07, etap 2.

Analiza wyników w etapie trzecim:

- dla podziału dwugrupowego zmniejszenie ilości pętli poskutkowało podobnymi wynikami jak w etapie pierwszym i drugim: podział na dzień i wieczór,
- dla podziału trójgrupowego zmniejszenie ilości pętli poskutkowało podobnymi wynikami jak w etapach poprzednich: zaburzenia okołoincydentalne – brak incydentu dzień - brak incydentu wieczór,
- dla podziału czterogrupowego zmniejszenie ilości pętli poskutkowało zawężeniem momentu incydentu (nr 4) oraz ukazuje w pewien sposób jego złożoność, z tego względu, że jest niejako podzielony na dwie części

```

Clustering vector:
[1] 1 2 1 1 1 1 1 2 1 2 1 1 1 1 1 2 2 1 2 2 2 1 2 2 2 2 2 1 2 1 1 1 1 1 2 2
[38] 2 1 1 2 1 2 2 2 2 2 2 1 1 1 1 1 2 2 1 1 1 1 1 2 1 1 1 1 1 2 1 2 2 1 1 2 2
[75] 2 2 2 2 2 2 2 2 2 2 2 2 2 1 2 2 2 1 2 2 2 2 1 2 2 2 2 1 2 2 1 1 2 2 2 1 1
[112] 1 2 2 2 2 2 2 2 2 2 2 2 2 1 2 2 2 2 2 2 4 4 2 4 2 2 2 2 2 4 4 2 2 2 2 2 2
[149] 2 4 4 4 2 4 4 4 4 4 4 2 2 2 4 4 4 4 4 4 4 4 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[186] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[223] 4 4 4 4 2 4 4 4 2 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[260] 2 1 1 1 2 1 2 2 2 1 1 2 2 2 1 1 2 2 2 1 1 1 2 2 2 1 1 1 2 2 2 1 1 2 2 1 2 1
[297] 1 2 2 1 2 1 1 2 2 2 1 2 1 1 2 2 2 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 1
[334] 2 2 2 1 2 2 1 2 1 1 2 1 2 2 2 1 2 1 1 1 1 1 1 2 3 2 1 2 2 2 1 1 2 2 2 1 1
[371] 1 1 2 1 2 1 1 2 1 2 1 2 2 1 1 1 1 1 1 1 2 1 1 2 2 2 1 1 1 2 2 1 1 2 1 1 2 2
[408] 1 1 1 1 2 1 1 1 3 2 1 1 1 1 1 2 2 1 2 1 2 2 1 2 2 1 2 2 2 1 1 1 2 1 1 1 1 1
[445] 1 1 1 1 1 1 1 1 1 2 2 1 1 1 1 1 1 1 1 1 2 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
[482] 1 1 1 1 1 1 1 1 1 1 3 1 3 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 2 1 1 1 1 1 1 1 1
[519] 3 3 3 3 3 1 1 3 1 3 1 1 3 3 3 1 3 3 3 1 3 1 3 1 3 1 3 1 3 1 3 1 3 1 3 1 3
[556] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3

```

Rysunek 67. Wektor klastujący 4-grupowo - dzień 25.07, etap 3.

Analiza wyników w etapie czwartym:

- dla podziału dwugrupowego zmniejszenie ilości pętli i parametrów poskutkowało podobnymi wynikami jak w etapach poprzednich: podział na dzień i wieczór,
- dla podziału trójgrupowego zmniejszenie ilości pętli i parametrów, poskutkowało podobnymi wynikami jak w etapach poprzednich: zaburzenia okołoincydentalne – brak incydentu dzień - brak incydentu wieczór,

- c) dla podziału czterogrupowego zmniejszenie ilości pętli i parametrów poskutkowało z kolei wydłużeniem teoretycznego momentu incydentu (nr 2) i prawdopodobna możliwością wcześniejszego wykrycia, pozostała część dnia dość zróżnicowana oprócz wieczoru (nr 1)

Clustering vector:

```
[1] 4 4 4 4 3 3 4 2 3 3 4 3 4 3 4 2 2 4 3 4 4 3 2 2 2 2 4 2 4 3 3 3 4 3 3 4 2
[38] 2 4 3 2 4 2 2 2 2 2 2 3 3 3 3 4 2 2 3 3 4 4 3 2 3 4 4 4 4 2 4 3 3 3 4 2 2
[75] 2 2 3 3 2 3 2 2 2 3 2 2 2 3 2 2 3 3 3 3 2 2 2 3 3 2 4 2 4 4 2 3 2 2 3 3
[112] 3 2 2 2 2 2 2 2 2 2 2 2 3 4 2 2 2 2 2 2 2 2 4 4 2 2 2 2 4 4 2 2 2 2 2 2
[149] 2 2 2 2 2 2 2 2 2 2 2 2 4 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[186] 2 2 4 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 4 2 2 2 2 2 4 4 2 2 2 2 4 2 2 2 2
[223] 2 2 4 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 4 2 2 2 2 2 2 2 2 2 2 2 4 2 2 2 2
[260] 2 4 3 3 3 3 2 2 2 3 3 3 3 2 3 4 3 2 4 3 3 2 2 2 4 4 3 2 2 3 4 4 2 2 3 3 3
[297] 4 4 2 3 3 3 4 3 2 2 3 2 3 3 4 2 2 3 3 2 4 2 3 3 3 2 2 2 3 4 3 3 3 2 2 2 3
[334] 3 4 3 4 3 2 3 2 3 3 2 3 4 3 3 3 3 3 3 3 3 3 3 3 2 4 2 3 2 2 4 3 3 4 3 2 4 4
[371] 4 3 2 4 2 3 3 4 3 4 4 3 2 4 3 3 3 3 4 3 4 4 3 4 3 3 3 3 2 3 3 4 2 3 1 4 2
[408] 3 3 3 3 3 3 3 4 1 3 4 3 4 4 4 4 2 3 4 3 3 4 4 3 3 4 3 3 3 4 3 4 3 1 3 3
[445] 4 1 1 3 3 4 3 3 4 4 4 3 3 4 3 4 3 4 4 3 4 4 4 4 1 3 3 4 4 4 4 3 4 3 1 3
[482] 3 1 3 4 4 3 1 3 4 3 1 1 1 4 4 3 1 4 4 1 1 4 3 4 1 3 3 4 3 4 4 3 4 1 1 3 1
[519] 1 1 1 1 1 1 4 1 4 1 4 3 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 4 1 3 1
[556] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
```

Rysunek 68. Wektor klastrujący 4-grupowo - dzień 25.07, etap 4

ANALIZA INCYDENTÓW SZTUCZNYCH:

- Dzień 11.05.

Analiza wyników w etapie pierwszym:

- dla podziału dwugrupowego nie ma możliwości odzyskania momentu incydentu, ruch można podzielić jedynie na dzienny i wieczorny,
- dla podziału trójgrupowego bezproblemowe wyodrębnienie grupy incydentalnej
- dla podziału czterogrupowego wyodrębniono grupę incydentalną oraz grupę dzienną, późno-popołudniową i wieczorną

Analiza wyników w etapie drugim:

- dla podziału dwugrupowego zmniejszenie ilości parametrów pozwoliło odszukać moment incydentu,
- dla podziału trójgrupowego bezproblemowe wyodrębnienie grupy incydentalnej
- dla podziału czterogrupowego wyodrębniono grupę incydentalną oraz grupę dzienną, późno-popołudniową i wieczorną

Analiza wyników w etapie trzecim:

- dla podziału dwugrupowego zmniejszenie ilości pętli również pozwoliło odszukać moment incydentu,
- dla podziału trójgrupowego bezproblemowe wyodrębnienie grupy incydentalnej
- dla podziału czterogrupowego wyodrębniono grupę incydentalną oraz grupę dzienną, późno-popołudniową i wieczorną

Analiza wyników w etapie czwartym:

- dla podziału dwugrupowego zmniejszenie ilości pętli oraz parametrów również w bezproblemowo pozwala wyodrębnić cykle incydentalne

- b) dla podziału trójgrupowego bezproblemowe wyodrębnienie grupy incydentalnej
- c) dla podziału czterogrupowego wyodrębniono grupę incydentalną oraz grupę dzienną, późno-popołudniową i wieczorną

- Dzień 12.05.

Analiza wyników w etapie pierwszym:

- a) dla podziału dwugrupowego nie ma możliwości odszukania momentu incydentu, ruch można podzielić jedynie na dzienny oraz wieczorny,
- b) dla podziału trójgrupowego podział jest wyraźny - wyodrębniona grupa cykli związanych z incydemem oraz cykle bez zdarzeń drogowych - dzienne i wieczorne,
- c) dla podziału czterogrupowego uwidoczniony jest podział na normalne warunki ruchu dzienne, moment incydentu drogowego, ruch późno-popołudniowy i wieczorny.

Analiza wyników w etapie drugim:

- a) dla podziału dwugrupowego zmniejszenie ilości parametrów nie polepszyło rezultatów, ruch można podzielić jedynie na dzienny oraz wieczorny,
- b) dla podziału trójgrupowego zmniejszenie ilości parametrów poskutkowało podobnymi wynikami jak w etapie pierwszym: podział na incydent – brak incydentu w dzień i wieczorem
- c) dla podziału czterogrupowego zmniejszenie ilości parametrów skutkowało następującymi wynikami: wyodrębniono grupę incydentalną, wymieszaną grupę poranną z popołudniową oraz oddzielną wieczorną.

Analiza wyników w etapie trzecim:

- a) dla podziału dwugrupowego zmniejszenie ilości pętli poskutkowało podobnymi wynikami jak w etapie pierwszym i drugim: ruch dzienny oraz wieczorny,
- b) dla podziału trójgrupowego zmniejszenie ilości pętli poskutkowało podobnymi wynikami jak w etapach poprzednich: podział na incydent – brak incydentu w dzień i wieczorem
- c) dla podziału czterogrupowego zmniejszenie ilości pętli poskutkowało podobnymi wynikami jak w etapie drugim: wyodrębniono grupę incydentalną oraz dzienna i wieczorną.

Analiza wyników w etapie czwartym:

- a) dla podziału dwugrupowego zmniejszenie ilości pętli i parametrów w końcu pozwoliło na zidentyfikowanie incydentu,
- b) dla podziału trójgrupowego zmniejszenie ilości parametrów i pętli poskutkowało podobnymi wynikami jak w etapach poprzednich: podział na incydent – brak incydentu w dzień i wieczorem,
- c) dla podziału czterogrupowego zmniejszenie ilości pętli i parametrów poskutkowało podobnymi wynikami jak w poprzednich etapach, ale z większym uporządkowaniem pory dnia: normalne warunki ruchu dzienne, moment incydentu drogowego, ruch późno-popołudniowy i wieczorny.

podział na clusters w dniu 21.04 jest zależny od pory dnia. Rankiem przeważa clusters 2 (z przerwą incydentalną). Ok. godz. 12:00 (cykl 200) zaczyna dominować clusters 3. Następnie pojawiają się klasy 5, 1 i 4.

- Incydent 13.05.2015

Clustering vector:

```
[1] 3 9 3 9 9 9 9 9 9 9 9 3 9 9 9 3 3 9 9 2 4 9 9 9 4 9 9 9 4 9 9 9 2 2 4 9 9 9 9 9 9 2 9 9 9 9
[47] 9 9 9 2 9 9 2 2 4 9 4 9 9 9 4 4 9 9 9 4 9 4 9 4 9 4 4 9 1 4 9 9 9 2 9 2 2 4 4 9 9 9 4 2 9 4
[93] 4 4 1 1 9 9 9 4 9 9 2 9 9 2 4 2 2 2 9 9 4 9 9 9 4 4 9 9 9 9 4 2 2 9 9 9 9 4 2 9 9 2 4 9 9 9
[139] 7 4 2 2 4 2 2 2 2 2 4 4 9 4 4 2 2 4 4 4 2 4 4 2 4 4 2 2 4 9 4 1 4 4 2 2 2 2 9 4 2 2 4 2 4 9 2
[185] 2 4 4 4 2 2 2 4 4 4 2 4 2 2 2 1 1 2 4 2 4 2 4 2 2 4 2 2 4 2 9 2 2 2 4 4 2 4 2 1 9 9 9 4 4 2 2 2
[231] 4 2 1 1 2 2 4 4 1 1 1 2 2 1 4 2 1 2 2 1 2 1 2 2 4 2 2 1 1 1 1 1 1 2 4 4 2 2 1 2 2 4 4 2 1
[277] 4 4 4 2 2 2 4 4 1 1 2 2 4 9 4 4 4 2 2 3 2 4 2 2 2 2 4 4 1 1 1 2 4 4 4 2 1 4 2 2 1 2 4 1
[323] 4 4 1 2 2 1 2 4 1 2 4 2 4 4 2 2 2 1 4 2 1 1 4 1 1 4 2 2 4 2 2 1 1 2 2 1 1 1 4 1 1 1 1 2
[369] 1 2 2 2 2 4 2 1 4 2 4 2 2 2 2 2 4 4 2 1 4 2 1 2 1 1 2 2 1 1 4 1 2 2 4 2 1 1 1 1 2 2 9 4 4 4
[415] 2 2 2 2 2 4 2 1 4 1 1 2 4 4 2 2 4 4 2 4 1 4 2 3 4 4 2 4 2 4 2 2 4 4 2 2 2 2 9 4 4 2 4 2 4
[461] 4 2 2 4 4 9 1 4 2 2 4 3 2 9 2 4 2 4 4 9 4 4 1 2 4 4 4 4 4 4 3 2 4 4 4 4 4 2 1 2 1 2 4 2
[507] 4 2 1 3 4 3 3 3 4 4 4 4 2 2 2 3 2 2 2 3 3 4 3 9 4 4 4 2 3 2 3 2 3 3 4 4 4 9 3 3 4 4 3 4 3 3
[553] 3 3 3 3 3 3 3 3 9 3 3 3 3 3 3 3 3 5 9 3 3 3 3 3 4 3 3 5 3 3 3 3 3 3 3 3 3 3 3 3 5 3 3 6 3
[599] 3 3 3 6 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 6 3 3 6 3 3 3 3 3 6 3 3 6 3 3 3 3 3 3 3 3 3 3 6 5 3
[645] 3 5 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5 5
[691] 5 5 6 5 6 5 6 8 5 6 8 5 5 6 5 6 5 6 5 5 6 5 5 6 5 6 6 5 5 6 6 5 6 6 8 5 3 6 6 6 6 8 6 6 8 5 6 6 5
```

Rysunek 70. Podział na 9 clusters dnia 13.05.2015 w programie R.

Incydent 13.05.2015 jest słabo wykrywany w programie R. Charakter ruchu w czasie incydentu jest podobny do ruchu porannego w wyniku czego program przypisał je do tej samej clusters. Mimo wszystko przy odpowiedniej konstrukcji nauczyciela sieć neuronowa może być w stanie wykryć ten incydent.

- Incydent 19.05.2015

Clustering vector:

```
[1] 6 6 6 6 6 6 6 6 6 6 6 6 6 6 4 6 6 6 6 6 6 6 6 6 6 1 6 6 6 6 6 6 6 6 6 6 6 1 2 6 6 7 6 6 6 6 7 6
[47] 6 6 6 6 6 6 6 6 6 6 6 6 6 6 1 6 6 6 6 6 6 7 1 6 1 6 6 6 6 1 2 6 6 6 6 6 6 7 7 6 6 6 6 6 6 6 6 6
[93] 6 6 6 6 6 7 1 7 6 7 6 1 6 6 1 6 6 6 7 1 1 7 6 6 6 7 7 6 6 6 6 4 6 6 6 6 6 7 7 1 7 7 6 6 6 7
[139] 6 1 7 6 7 7 6 6 6 7 7 6 1 7 1 7 6 7 7 7 6 6 1 1 1 7 1 7 7 7 1 7 1 5 5 5 1 5 5 5 7
[185] 5 5 5 1 5 1 5 5 5 5 5 5 5 5 5 5 5 1 7 7 7 6 7 1 7 7 7 1 7 7 7 1 7 7 7 6 6 7 7 1 6 1 1 7
[231] 7 1 7 7 1 1 1 1 7 7 7 7 1 7 7 1 1 1 7 7 1 7 1 7 7 1 7 7 1 7 7 1 7 7 7 1 1 1 1 1 7 1 1 6 1 1
[277] 1 1 7 1 1 1 1 7 6 1 7 7 1 7 2 7 7 7 2 7 1 1 1 1 1 1 1 1 7 1 2 7 1 1 7 1 7 7 7 1 7 7 1 7 1
[323] 7 2 1 2 7 1 1 7 1 1 7 1 7 7 7 1 7 1 1 7 7 7 1 7 3 1 7 7 1 7 7 1 1 1 1 7 1 7 7 7 1 7 1 1
[369] 1 7 7 1 7 1 7 1 7 1 1 7 7 7 1 7 1 7 1 7 7 1 1 1 7 7 1 7 7 7 7 1 7 1 1 1 7 7 1 7 1 7 7 7 7
[415] 7 7 1 1 1 1 1 2 7 1 7 1 7 6 1 1 7 1 7 1 7 1 7 2 7 7 1 7 7 6 6 1 6 7 1 7 7 7 1 7 7 4 7 1
[461] 1 7 1 1 7 1 1 1 7 7 7 1 6 7 1 7 1 7 7 1 1 1 1 7 1 7 1 7 1 7 1 7 1 7 1 1 7 1 1 7 1 7 4 4 1 7 1 7
[507] 1 1 7 4 1 1 7 1 1 7 7 7 1 4 1 7 1 7 7 7 1 1 6 4 4 4 4 1 4 4 7 6 4 4 4 4 6 4 4 6 4 4 4 4 4 4
[553] 4 4 6 4 4 4 4 7 7 1 4 4 4 4 6 7 4 1 4 4 4 7 7 4 4 4 4 4 4 4 4 3 4 6 4 4 4 4 4 4 4 4 4 4 4 4
[599] 4 4 4 1 4 4 4 4 4 4 1 4 7 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[645] 3 4 3 4 4 4 4 4 4 4 3 3 4 4 4 4 4 4 4 3 3 4 3 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
[691] 3 3 3 4 3 4 4 4 4 4 4 3 3 3 4 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 4 4 3 3 4 3 4 3 3 3 4 4 3 3 3
[737] 4 4 3 3 3 4 3 3 3 3 4 3 3 3 3
```

Rysunek 71. Podział na 7 clusters dnia 19.05.2015 w programie R.

Incydentowi 19.05.2015 (cykle 178-204) została przypisana osobna klasa. Podobnie jak 21.04 pojawiają się też inne clusters. Wyraźnie można zauważyć podział na ruch poranny, dzienny i wieczorny.

- Incydent 6.03.2015

Wypadek, mimo iż zdarzył się w godzinach porannych jest wykrywany w programie R jako osobny clusters. Można zauważyć, że charakter wypadku jest dobrze rozróżniany przez


```

Clustering vector:
[1] 2 2 2 4 4 2 2 4 4 4 2 2 2 3 3 2 4 4 2 3 4 3 4 3 3 3 2 3 2 3 3 3 3 4 3 4 3 3 2 2 3 4 4 4 3
[47] 2 2 3 2 2 4 3 3 4 4 3 3 2 3 3 3 3 3 4 2 3 2 3 2 2 4 3 3 4 4 4 6 4 2 4 6 3 2 3 3 2 2 4 3 2 2
[93] 2 2 4 4 6 6 2 4 3 4 2 4 3 3 2 2 3 3 4 6 3 3 3 3 3 3 4 3 3 4 3 3 3 4 3 3 2 4 4 3 2 4 4 3 3 3
[139] 2 4 2 6 3 4 4 3 3 6 3 6 3 3 4 4 4 6 6 3 3 6 3 3 6 2 3 4 6 2 4 3 3 3 2 3 2 3 3 4 6 3 3 3 3
[185] 2 2 3 3 6 6 3 6 2 6 6 3 6 6 6 3 2 6 6 2 2 3 3 2 3 3 6 3 3 2 4 6 6 4 3 3 3 6 6 3 3 6 6 3 3 3
[231] 3 3 3 3 6 3 3 6 3 3 6 3 6 6 3 6 6 3 6 6 6 6 6 6 6 6 6 6 6 3 3 4 3 3 6 3 6 3 3 6 3 3 6 6 3 6 6 2
[277] 2 2 6 6 3 6 6 6 6 6 4 3 6 3 6 6 6 3 6 6 6 6 6 6 6 6 6 6 6 6 6 3 6 6 6 6 6 2 3 6 3 6 6 6 6 6 6 6
[323] 3 6 6 6 2 3 3 2 6 3 6 3 6 6 3 6 6 3 6 6 6 6 6 6 6 6 6 6 6 6 6 2 6 4 6 6 6 6 6 6 6 6 6 6 6 6 6 6
[369] 6 3 6 6 6 6 6 6 6 6 6 6 6 3 3 6 4 3 6 3 6 6 3 6 6 6 6 6 6 6 6 2 6 3 3 3 6 2 4 3 6 6 6 2 6 4 6 3 2 3
[415] 3 3 3 2 6 6 2 6 3 4 4 2 4 4 6 2 3 3 6 4 4 2 2 4 2 2 4 4 4 3 3 3 3 2 3 6 4 4 4 6 2 6 2 3 3 3 3
[461] 4 2 4 4 2 2 3 6 2 3 3 4 6 6 4 6 4 4 2 6 4 4 2 2 4 6 4 2 4 3 6 2 4 4 4 4 2 4 2 2 4 2 2 2 4 2 2 4 2
[507] 4 4 2 3 4 6 4 4 4 2 2 2 2 1 4 2 2 4 2 2 2 4 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 4 2 7 4
[553] 2 7 2 7 2 4 5 4 4 2 4 7 7 5 2 2 4 2 2 7 2 2 1 7 2 4 4 7 2 1 7 7 7 7 1 1 1 7 7 7 7 7 7 2 2 7 7
[599] 7 7 5 7 7 7 7 7 1 7 1 5 1 7 1 7 7 5 7 7 7 7 5 7 7 2 7 7 7 7 7 7 7 1 7 7 7 7 7 7 1 7 5 7 5 7
[645] 7 1 7 1 7 7 1 7 5 5 7 7 7 7 5 7 7 1 7 7 1 1 1 7 7 7 5 5 7 7 5 5 5 5 7 5 5 1 5 7 1 7 5 5 5
[691] 1 1 1 5 5 7 5 7 7 5 7 1 7 5 5 7 1 1 5 7 1 7 1 7 7 5 5 1 7 5 5 1 5 7 1 7 5 5 5 5 5 5 5 1 5 5
[737] 7 7 5

```

Rysunek 75. Podział na 7 clusters dnia bez incydentu 6.05.2015 w programie R.

```

Clustering vector:
[1] 3 3 3 3 6 3 6 7 3 7 3 6 6 3 3 6 3 3 6 3 3 6 3 3 6 6 6 6 3 3 3 6 6 6 3 3 6 6 6 6 1 3 3 3 6 3 3 6 6
[47] 3 6 3 3 3 6 6 3 6 6 3 6 7 6 6 3 3 6 3 3 6 6 1 1 3 5 6 5 1 3 6 3 6 6 6 3 3 6 3 6 6 6 3 3 6 3
[93] 6 6 6 6 6 6 6 6 6 6 6 3 6 7 3 3 3 6 5 3 6 7 6 6 6 3 3 6 5 6 5 6 1 3 3 7 3 6 6 3 1 3 6 6 6 6 6
[139] 6 6 1 3 6 6 6 6 1 6 6 6 5 6 3 6 5 5 6 3 6 6 6 1 5 1 3 3 6 6 6 5 1 3 1 5 3 6 6 3 5 6 6 6 6 6
[185] 6 6 6 6 3 1 1 6 5 5 5 1 1 5 1 1 1 5 6 6 1 5 6 1 5 5 5 5 6 1 5 3 6 6 5 5 6 5 3 6 5 1 6 3 6 3
[231] 3 6 3 3 3 1 6 6 1 6 5 6 5 1 6 5 5 1 5 1 5 1 1 5 5 6 6 1 5 6 6 6 1 3 1 1 3 6 6 1 5 6 5 6 6 3
[277] 5 1 5 1 1 6 3 6 3 1 1 5 6 6 3 6 1 5 6 1 5 3 1 5 1 5 3 5 5 1 5 5 5 5 1 6 3 3 5 5 1 1 5 5 1 5
[323] 1 5 5 1 1 1 1 5 6 6 5 5 6 1 5 5 1 1 5 5 5 5 5 1 1 3 1 1 1 1 3 1 5 1 1 1 5 5 1 5 5 1 5 5 5
[369] 5 5 5 1 5 1 1 1 1 5 5 1 5 1 5 5 5 5 5 3 1 5 5 1 1 5 5 5 1 1 1 6 5 5 1 1 3 6 1 6 6 1 1 3 3 6
[415] 6 3 5 1 1 3 6 6 6 1 5 3 6 3 6 1 5 3 5 6 5 1 6 3 5 1 5 3 3 5 1 6 6 6 3 6 5 3 6 6 6 6 6 3 6 6
[461] 6 6 6 1 6 6 1 1 6 3 6 3 3 3 6 3 6 1 3 3 3 6 3 3 5 1 5 6 6 1 6 7 5 5 6 6 7 6 1 6 3 3 6 3 3
[507] 3 3 3 3 6 1 1 6 3 6 3 3 7 3 3 6 6 3 3 3 7 6 3 6 3 3 3 7 3 6 7 7 7 3 7 3 6 6 6 3 3 7 3
[553] 7 7 7 3 7 7 7 3 6 6 7 7 7 7 7 3 7 7 7 7 7 3 6 7 3 7 6 3 7 7 7 7 7 7 7 7 7 7 7 7 7 7 7 7 3
[599] 7 7 7 7 7 7 7 7 7 7 7 7 7 4 7 7 7 7 2 3 7 7 7 7 7 2 7 7 7 7 4 7 4 7 7 2 4 2 7 7 7 3 7
[645] 7 7 7 7 7 4 2 7 7 7 7 2 7 2 4 7 4 2 2 2 7 4 7 4 7 2 7 4 2 7 4 4 4 2 7 2 4 7 4 4 2 4 7
[691] 2 4 2 2 4 2 2 4 4 7 2 2 4 2 4 2 4 2 2 2 4 2 4 4 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
[737] 4 4 4 2 2 2 2 2 2 4 4 2 4 2 4 2

```

Rysunek 76. Podział na 7 clusters dnia bez incydentu 12.05.2015 w programie R.

Po przeanalizowaniu sklastrowania dni bez wypadku trudno jest doszukać się jakichkolwiek anomalii. Poszczególne klastry następują po sobie, nie zauważono klasy, która wyróżniałaby się i swoim występowaniem przypominałaby incydent. W związku z otrzymanymi wynikami, zarówno dla dni incydentalnych, jak i dni bez wypadku, wywnioskowano, że sieć neuronowa poradzi sobie z wykrywaniem incydentów przy wykorzystaniu formatu danych wprowadzanych do programu R. Wyniki dają duże prawdopodobieństwo otrzymania satysfakcjonujących rezultatów automatycznego wykrywania incydentów po właściwym zbudowaniu nauczyciela w Scilabie.

Do utworzenia nauczyciela wykorzystano wiedzę na temat wszystkich incydentów, ich strukturze i wpływie na rozkład ruchu na skrzyżowaniu. Na podstawie każdego z wypadków utworzono 71 wierszy wypadkowych, których wpływ na układ skrzyżowania oceniono jako duży (21.04, 6.03, 19.05, 19.03) i przypisano im wartości wynikowe 1 (incydent, który uniemożliwia ruch na przynajmniej jednym wlocie skrzyżowania na przynajmniej kilka cykli). W oparciu o rozkład ruchu podczas tych wypadków utworzono 5 wierszy symulujących wypadek na 7 pętli indukcyjnej. Dodatkowo utworzono 9 wierszy na podstawie danych z wypadku 13.05, których wartości wynikowe określono na 0,85. Oprócz tego dodano 120 wierszy z różnych pór dnia z

dni bezwypadkowych (6-21.05) oraz dni z incydem, których wartość wynikową określono jako 0 (brak wypadku).

Przy okazji analizy w programie R zauważono, że ruch poranny i wieczorny podczas różnych dni jest zupełnie inaczej klasyfikowany, dlatego przy konstrukcji nauczyciela starano się wybrać najbardziej reprezentatywne wiersze, które oddają charakter ruchu porannego/nocnego. W niektórych przypadkach cykle wypadkowe wyglądały podobnie do cykli porannych, bądź nocnych, dlatego koniecznym było ograniczenie tychże wierszy, aby cykl wypadkowy był dobrze wykrywalny.

5.6. Analiza PCA

Analiza głównych składowych (ang. Principal Component Analysis, PCA) jest jedną ze statystycznych metod analizy czynnikowej. Zbiór danych składający się z N obserwacji, z których każda obejmuje M zmiennych, interpretuje się zazwyczaj jako chmurę N punktów w przestrzeni M -wymiarowej. Celem PCA jest odpowiedni obrót układu współrzędnych, tak aby maksymalizować w pierwszej kolejności wariancję pierwszej współrzędnej, a następnie drugiej współrzędnej i każdej kolejnej, itd. Przekształcone wartości współrzędnych określa się jako ładunki wygenerowanych czynników (składowych głównych). W ten sposób konstruowana jest nowa przestrzeń obserwacji, w której najwięcej zmienności wyjaśniają początkowe czynniki. PCA jest często używana do zmniejszania rozmiaru zbioru danych statystycznych, poprzez odrzucenie ostatnich, najmniej istotnych czynników. Przydatna jest również do merytorycznej interpretacji czynników, zależnej od rodzaju danych, co pozwala lepiej zrozumieć naturę danych, choć bywa trudne przy większej liczbie badanych zmiennych [5].

PCA może być oparte na dwóch typach macierzy: korelacji lub kowariancji utworzonych ze zbioru wejściowego. Algorytm w obydwu wersjach jest opracowywany identycznie, ale uzyskane wyniki mogą być zupełnie różne. W przypadku użycia macierzy kowariancji, zmienne w zbiorze wejściowym o największej wariancji mają największy wpływ na wynik, co może być wskazane, jeśli zmienne reprezentują porównywalne wielkości. Użycie macierzy korelacji natomiast odpowiada wstępnej normalizacji zbioru wejściowego tak, aby każda zmienna miała na wejściu identyczną wariancję, co może być wskazane, jeśli wartości zmiennych nie są porównywalne [5].

Dla wcześniej opisywanych wypadków, na których bazowano w badaniach, postanowiono przeprowadzić analizę PCA, czyli analizę głównych składowych. Czynność tą wykonano z tej racji, że na etapie wstępnych analiz w oprogramowaniu R poddano pod wątpliwość, czy konieczne jest użycie parametrów określających czas spędzony na pętli – „ t ” oraz odległość czasową pomiędzy kolejnymi wzbudzeniami pętli – „ d ”. Przede wszystkim te parametry są zależne zarówno od parametrów ilości wzbudzeń, jak i prędkości, dlatego do poprawnego przeprowadzenia badań przy jednoczesnym zaoszczędzeniu czasu i rozmiaru danych wystarczające wydaje się użycie głównych parametrów pozyskanych z pętli – prędkości „ v ” oraz ilości wzbudzeń „ i ”. Rezultaty analizy znajdują się na rys. 77.

	PC1	PC2		
Duration	0.089434867	-0.020063573	PC_9_Ile	-0.089246275 0.094513253
PC_0_Ile	-0.163776142	0.075267323	PC_9_V	0.189443072 0.129626092
PC_0_V	0.229241815	0.103358649	PC_9_L	-0.007125711 0.034793742
PC_0_L	0.015080835	-0.036763942	PC_9_T	-0.111309265 -0.084714397
PC_0_I	-0.170213238	-0.139145295	PC_9_D	0.025866612 -0.035010331
PC_0_D	0.170591598	-0.074759876	PC_10_Ile	-0.044765143 0.110673584
PC_1_Ile	-0.087641351	0.070191506	PC_10_V	0.178681834 0.186945239
PC_1_V	0.245475258	0.048540113	PC_10_L	-0.046660640 -0.136128887
PC_1_L	-0.035594624	-0.098257687	PC_10_T	-0.137673930 -0.193532161
PC_1_I	-0.174667787	-0.100112215	PC_10_D	0.061291402 -0.142772883
PC_1_D	0.130592444	-0.027571711	PC_11_Ile	0.015582299 0.067326219
PC_2_Ile	-0.047333238	0.104735635	PC_11_V	0.192475386 0.021807357
PC_2_V	0.215863195	0.010963776	PC_11_L	-0.079108623 -0.077443524
PC_2_L	0.060199028	0.107377041	PC_11_T	-0.132858463 -0.066111925
PC_2_I	-0.111844073	-0.079720035	PC_11_D	0.044332832 -0.054998226
PC_2_D	-0.061645659	-0.070105338	PC_12_Ile	0.110444582 -0.073812359
PC_3_Ile	-0.084007147	0.142624003	PC_12_V	0.192584163 -0.056755859
PC_3_V	0.222645334	-0.067344459	PC_12_L	-0.037715992 -0.176650800
PC_3_L	-0.020004186	0.085330986	PC_12_T	-0.135491094 -0.064600660
PC_3_I	-0.143289625	0.071719414	PC_12_D	0.035031548 0.050971348
PC_3_D	-0.057248329	-0.187752286	PC_13_Ile	0.056299331 0.049195659
PC_4_Ile	0.010050018	-0.184178304	PC_13_V	0.206327103 -0.034616068
PC_4_V	0.041519866	-0.212183855	PC_13_L	-0.048691493 -0.020189672
PC_4_L	0.007428056	-0.084569759	PC_13_T	-0.151763677 -0.104973307
PC_4_I	-0.045636080	0.107358062	PC_13_D	-0.044693731 0.068815071
PC_4_D	0.105565346	0.062341277	PC_14_Ile	-0.033361267 0.172752084
PC_5_Ile	-0.041475441	-0.118831315	PC_14_V	0.193206355 -0.113547001
PC_5_V	0.065253943	0.270152924	PC_14_L	-0.087994400 0.060891862
PC_5_L	-0.013070356	0.009540498	PC_14_T	-0.126868577 0.045709485
PC_5_I	-0.054502285	0.169420073	PC_14_D	-0.035482040 -0.161933273
PC_5_D	0.019702556	0.123112127	PC_15_Ile	-0.035019131 0.019284524
PC_6_Ile	-0.055533660	0.268170254	PC_15_V	0.180046716 -0.152856619
PC_6_V	0.117327545	0.014314999	PC_15_L	-0.076216099 0.142749555
PC_6_L	-0.013423284	0.177652724	PC_15_T	-0.109658527 0.111771740
PC_6_I	-0.093861796	0.073895730	PC_15_D	0.018915810 -0.055079107
PC_6_D	-0.004345363	-0.261134734		
PC_7_Ile	-0.071810555	0.076331691		
PC_7_V	0.165657843	0.018019240		
PC_7_L	0.010117322	0.110389801		
PC_7_I	-0.146282910	-0.045717886		
PC_7_D	0.007701344	-0.032760014		
PC_8_Ile	-0.072280828	-0.027493796		
PC_8_V	0.156454978	-0.066107486		
PC_8_L	0.053402539	-0.024464064		
PC_8_I	-0.091560978	-0.023864127		
PC_8_D	0.052269516	0.083382656		
PC_9_Ile	-0.089246275	0.094513253		
PC_9_V	0.189443072	0.129626092		
PC_9_L	-0.007125711	0.034793742		
PC_9_T	-0.111309265	-0.084714397		
PC_9_D	0.025866612	-0.035010331		

Rysunek 77. Fragment wyników analizy PCA.

Jak widać na powyższym rysunku zaznaczono najwyższe, skrajne współczynniki dodatnie i ujemne, które mają najwyższy wpływ na rezultaty. Prawie wszystkie z nich związane są albo z parametrem prędkości, albo ilością wzbudzeń. Lepsze zobrazowanie sytuacji można dostrzec na poniższym rysunku przedstawiającym wektory poszczególnych parametrów.

5.7. Program Scilab.

Najważniejszym etapem po odpowiedniej obróbce i analizie otrzymanych danych jest przetworzenie ich w programie. Do tego celu należało opracować odpowiedni skrypt w środowisku SCILAB. Aby możliwe było wykonywanie operacji na sieciach neuronowych należało zainstalować odpowiedni dodatek „Artificial Neural Network”.

```
1 dane=read("d:\nauczyciel.txt",149,57);
2
3 N=[57 200 200 200 1]; .....
4 lp=[0.1 0.05 0.5 0.1]; .....
5 Te=300; .....
6 P=[dane(1:149,:)];
7 P=P';
8 T=zeros(1,149);
9 T(1,1:71)=1;
10 T(1,72:80)=0.75;
11 W=ann_FF_init(N); .....
12 [W,sW]=ann_FF_Mom_online(P,T,N,W,lp,Te); .....
13 write("d:\nf\wag3.txt",W(:)); .....
14 Y=ann_FF_run(P,N,W);
```

Rysunek 79. Kod w programie Scilab®, poznanie nauczyciela.

Pierwszym krokiem w programie Scilab® jest wczytanie pliku z nauczycielem w formacie txt (dostępne są również inne formaty: csv, xlsx, itd.) wraz z podaniem liczby wierszy oraz kolumn pliku. Następnie należy podać architekturę sieci (N). Pierwsza liczba jest to liczba wejść, czyli liczba, w tym przypadku, kolumn utworzonego nauczyciela. Ostatnia liczba jest to liczba wyjść, czyli to co ma zwracać sieć neuronowa. W opisywanym programie będzie to jedna liczba mówiąca o prawdopodobieństwie wystąpienia incydentu. Środkowe liczby jest to schemat budowy warstw sieci neuronowej, które prowadzą do otrzymania pożądanego wyniku. Im bardziej rozbudowana architektura sieci, tym dłuższy jest proces uczenia, jednakże poprawia się skuteczność rozpoznawania nauczyciela. W kolejnym kroku należy podać liczbę epok uczenia (Te). Podobnie jak złożoność architektury wpływa na długość procesu uczenia. Następnie należy przypisać wartości wynikowe dla nauczyciela (T). To znaczy przypisać, które z wierszy są incydemem (1), a które nie (0). Sposób konstruowania nauczyciela jest inny dla różnych skrzyżowań. Po inicjalizacji wag można przejść do procesu uczenia. Wynikiem tego procesu jest macierz wag (W), który jest parą z wektorem N. Po zapisie macierzy wag do pliku wyświetlana jest macierz Y, która informuje o wyniku procesu nauki. Im wyniki bliższe 1, tym większe poznanie nauczyciela.

Jeszcze przed wprowadzeniem danych do sieci neuronowej należy poddać je standaryzacji lub normalizacji. Proces ten można wykonać w środowisku zewnętrznym lub w środowisku Scilab. Poniżej przedstawiono proces konwersji danych w środowisku Scilab.

```

a) 7 for i=1:30
    8     av(1,i)= mean({dane(:,i)});
    9     o(1,i)= stdev({dane(:,i)}); ...
   10 end
   11
   12 for i=1:30
   13     danest(:,i) = (dane(:,i)-av(1,i))/ o(1,i)
   14 end

b) 7 for i=1:30
    8     maxy(1,i)=max({dane(:,i)});
    9     miny(1,i)=min({dane(:,i)}); ...
   10 end
   11
   12 for i=1:30
   13     danenor(:,i) = (dane(:,i)-miny(1,i))/(maxy(1,i)-miny(1,i));
   14 end

```

Rysunek 80. Element skryptu – a) standaryzacja, b) normalizacja.

```

1 dane2=read("d:\nf\2104.txt", 737, 57);
2 P1=[dane2(1:737, :)];
3 P1=P1';
4
5 W1=ann_FF_init(N); ...
6 [a,b,c]=size(W1);
7
8 W2=read("d:\nf\wag3.txt", 1, a*b*c); .....
9 W3=matrix(W2, a, b, c);
10 Y1=ann_FF_run(P1,N,W3) .....
11 write("d:\wyniki\wynik2104.txt", Y1 (:)); ...

```


Rysunek 81. Kod w programie Scilab, wykrywanie incydentów.

Gdy wyznaczono już macierz wag W , można przystąpić do kolejnego etapu, czyli rozpoznawania i klasyfikacji wczytanych danych jako incydent lub nie. Macierz $Y1$ jest wynikiem tego procesu. Zwracane jest prawdopodobieństwo wystąpienia w danym cyklu incydentu. Wyniki te są następnie zapisywane do pliku.

6.0. Analiza wyników.

6.1. Skrzyżowanie Morska/Owsiana.

W tym rozdziale przedstawiono wyniki wszystkich badań przeprowadzonych w oprogramowaniu Scilab, przy użyciu różnych kombinacji zbiorów uczących i testowych, w celu odnalezienia tych najskuteczniejszych. Każda z przeprowadzonych obserwacji, nawet tych teoretycznie nieudanych, przyniosła niezbędne informacje, które wykorzystano w doborze teoretycznie najlepszych zbiorów uczących. Należy podkreślić, że przeprowadzone w tej pracy wszelkie badania miały charakter pierwotnych testów, które mogą zostać w późniejszym czasie wykorzystane w bardziej zaawansowanych badaniach dotyczących wykrywania incydentów w Gdyńskiej sieci miejskiej z wykorzystaniem sieci neuronowych. Niestety ze względu na niewielki potencjał danych, jakimi dysponowano podczas opracowania, badania te należy traktować jako mały krok naprzód weryfikujący przydatność użycia sztucznych sieci neuronowych w tej dziedzinie.



Rysunek 82. Uproszczony schemat procesu analizy skrzyżowania MORSKA-OWSIANA (opr. własne)

ANALIZA 1

Pierwszą analizą przeprowadzono jedynie z wykorzystaniem prawdziwych incydentów, jakie udało się pobrać z centrum TRISTAR, czyli zbiór uczący utworzono z danych z dnia 5.05 oraz 24.07, a zbiór testowy z dnia 25.07. Przyjęto najoptymalniejszą architekturę sieci:

- 3 warstwy ukryte po 300 neuronów **N = [300 300 300]**
- Parametry procesu uczenia : **lp = [1 0.05 0.5 1]**
- Liczba epok uczenia: **Te = [300]**

Przeprowadzono 4 typy testów:

- a) TEST A – wszystkie pętle; parametry i, v; standaryzacja
- b) TEST B – istotne pętle; parametry i, v; standaryzacja
- c) TEST C – wszystkie pętle; parametry i, v; normalizacja
- d) TEST D – istotne pętle; parametry i, v; normalizacja

Pułap alarmowy w powyższych przypadkach przyjęto na poziomie $y=0,6$ dla kilku następujących po sobie cykli.

Opis:

Ad. a)

- Wyniki zbioru uczącego są pozytywne, wartości nauki poszczególnych cykli zbliżone do oczekiwanych,
- Test nieudany, wartości nie przekraczają pułapu $y=0,07$, nie ma możliwości zaalarmowania incydentu.

Ad. b)

- Wyniki zbioru uczącego wciąż są pozytywne, wartości nauki poszczególnych cykli zbliżone do oczekiwanych,
- Test nieudany, wartości nie przekraczają pułapu $y=0,28$, nie ma możliwości zaalarmowania incydentu.

Ad. c)

- Wyniki zbioru uczącego pogorszyły się, pomiędzy wartości pozytywne wkradły się błędy, wartości nauki cykli 675-735 kompletnie nieudane,
- Wyniki testu są nieistotne, co spowodowane jest złymi wynikami zbioru uczącego

Ad. d)

- Wyniki zbioru uczącego podobne jak w przypadku c), liczne błędy niepokrywające się z wartościami oczekiwanyymi,
- Wyniki testu są nieistotne, co spowodowane jest złymi wynikami zbioru uczącego

Po przeprowadzeniu tego badania nie należy wyciągać daleko idących wniosków, jednakże można dostrzec znaczne różnice w wynikach zbiorów testowych w zależności od sposobu normalizacji. Standaryzowanie danych pozwoliło uzyskać oczekiwany zbiór uczący, w przeciwieństwie do danych znormalizowanych, do których wkradły się niepożądane błędy.

ANALIZA 2

Drugą analizę przeprowadzono także z wykorzystaniem prawdziwych incydentów, ale tym razem zbiór uczący utworzono z danych z dnia 5.05 oraz 25.07, a zbiór testowy z dnia 24.07. Celem było sprawdzenie zależności pomiędzy podobnymi incydentami z 24 i 25.07, czyli sprawdzenie jak zachowa się sieć po zamianie danych i próba wyciągnięcia wniosków z nieudanej poprzedniej analizy. Przyjęto najoptymalniejszą architekturę sieci:

- 3 warstwy ukryte po 300 neuronów **N = [300 300 300]**
- Parametry procesu uczenia : **lp = [1 0.05 0.5 1]**
- Liczba epok uczenia: **Te = [300]**

Przeprowadzono analogiczne 4 typy testów:

- a) TEST A – wszystkie pętle; parametry i, v; standaryzacja
- b) TEST B – istotne pętle; parametry i, v; standaryzacja
- c) TEST C – wszystkie pętle; parametry i, v; normalizacja
- d) TEST D – istotne pętle; parametry i, v; normalizacja

Pułap alarmowy w powyższych przypadkach przyjęto na poziomie $y=0,6$ dla kilku następujących po sobie cykli.

Opis:

Ad. a)

- Wyniki zbioru uczącego są pozytywne, wartości nauki poszczególnych cykli zbliżone do oczekiwanych,
- Test nieudany, wartości nie przekraczają pułapu $y=0,07$, nie ma możliwości zaalarmowania incydentu.

Ad. b)

- Wyniki zbioru uczącego wciąż są pozytywne, wartości nauki poszczególnych cykli zbliżone do oczekiwanych,
- Test nieudany, wartości nie przekraczają pułapu $y=0,01$, nie ma możliwości zaalarmowania incydentu.


Ad. c)

- W wyniki zbioru uczącego wkradły się błędy, wartości nauki cykli 666-701 inne niż oczekiwane,
- Wyniki testu są nieistotne, co spowodowane jest złymi wynikami zbioru uczącego


Ad. d)

- Wyniki zbioru uczącego podobne jak w przypadku c), liczne błędy niepokrywające się z wartościami oczekiwanyymi,
- Wyniki testu są nieistotne, co spowodowane jest złymi wynikami zbioru uczącego.

Testy wypadły niemal identycznie jak dla poprzedniej kombinacji, ciężko wywnioskować dlaczego po raz kolejny, ale w innej kombinacji, wyniki okazały się nieużyteczne. Prawdopodobnie problem leży w konstrukcji poszczególnych incydentów. W tym celu postanowiono odnaleźć przyczynę problemu, poprzez analizę porównawczą problematycznych danych z dni z incydem, czyli 24.07 i 25.07.



Rysunek 83 Wektoryzacja incydentów z oznaczoną chmurą punktów z incydem (normalizacja lokalna):
a) 24.07, b) 25.07.



Rysunek 84. Wektoryzacja incydentów z oznaczoną chmurą punktów z incydem (24.07 – czarny, 25.07 – czerwony) w normalizacji globalnej.

Jak widać na rys. 84 oddzielna normalizacja danych pozwala na bezproblemowe wyodrębnienie cykli incydentalnych. Niestety podczas wspólnej normalizacji globalnej obu dni (rys. 84), cykle incydentalne z dnia 25.07. zlewają się z cyklami bez incydentu z dnia 24.07, co jest główną przyczyną nieudanych testów.


ANALIZA 3


Po uwzględnieniu wcześniejszych nieudanych prób przy pracy jedynie z incydentami rzeczywistymi, tym razem postanowiono dołączyć sztucznie opracowane incydenty, mające usprawnić działanie zbioru uczącego, a zarazem doprowadzić do odzyskania najefektywniejszego. W tym wypadku zbiór uczący składa się jedynie z dnia 11.05, a testowi podlegają dni 24.07 i 25.07. Należy podkreślić, że po wyciągnięciu wniosków z poprzednich analiz, tym razem obie części zbioru testowego normalizowano oddzielnie (lokalnie). Przyjęto najoptymalniejszą architekturę sieci:

- 3 warstwy ukryte po 300 neuronów **N = [300 300 300]**
- Parametry procesu uczenia : **lp = [1 0.05 0.5 1]**
- Liczba epok uczenia: **Te = [300]**

Po raz kolejny przeprowadzono standardowo 4 typy testów:

- a) TEST A – wszystkie pętle; parametry i, v; standaryzacja
- b) TEST B – istotne pętle; parametry i, v; standaryzacja
- c) TEST C – wszystkie pętle; parametry i, v; normalizacja
- d) TEST D – istotne pętle; parametry i, v; normalizacja






Rysunek 85. Wyniki prawdopodobieństwa incydentu TEST A: a) dla zbioru uczącego 11.05, b) dla zbioru testowego 24.07, c) dla zbioru testowego 25.07.

Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydentalne
- incydent dla dnia 24.07, dla poziomu alarmowego 0.9, wykryto z bardzo wysoka skutecznością, jedynie kilka cykli zostało niewykrytych,
- nie zanotowano żadnych fałszywych alarmów w dniu 24.07
- incydent dla dnia 25.07, dla poziomu alarmowego 0.9, wykryto z około 50% skutecznością, największym problemem okazuje się słabe wykrycie pierwszych cykli incydentalnych,
- zanotowano 4 fałszywe alarmy




Rysunek 86. Wyniki prawdopodobieństwa incydentu TEST B: a) dla zbioru uczącego 11.05, b) dla zbioru testowego 24.07, c) dla zbioru testowego 25.07.


Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydentalne
- incydent dla dnia 24.07, dla poziomu alarmowego 0.9, wykryto z bardzo wysoka skutecznością, jedynie kilka cykli (5) zostało niewykrytych,
- nie zanotowano żadnych fałszywych alarmów w dniu 24.07
- incydent dla dnia 25.07, dla poziomu alarmowego 0.9, wykryto z około 50% skutecznością, największym problemem okazuje się słabe wykrycie pierwszych cykli incydentalnych,
- zanotowano 7 fałszywych alarmów


a)



b)



c)





Rysunek 87. Wyniki prawdopodobieństwa incydentu TEST C: a) dla zbioru uczącego 11.05, b) dla zbioru testowego 24.07, c) dla zbioru testowego 25.07.

Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydentalne
- incydent dla dnia 24.07, dla poziomu alarmowego 0.9, wykryto z bardzo wysoka skutecznością, jedynie kilka cykli (3) zostało niewykrytych,
- nie zanotowano żadnych fałszywych alarmów w dniu 24.07
- incydent dla dnia 25.07, dla poziomu alarmowego 0.9, wykryto z około 60% skutecznością,
- zanotowano dużą ilość (ok. 40%) fałszywych alarmów, niepozwalających na skuteczne odróżnienie cykli incydentalnych

a)





Rysunek 88. Wyniki prawdopodobieństwa incydentu TEST A: a) dla zbioru uczącego 11.05, b) dla zbioru testowego 24.07, c) dla zbioru testowego 25.07.

Opis:

- Sieć nauczyła się ze skutecznością 100%
- incydent dla dnia 24.07, dla poziomu alarmowego 0.9, wykryto ze 100% skutecznością,
- nie zanotowano żadnych fałszywych alarmów w dniu 24.07
- incydent dla dnia 25.07, dla poziomu alarmowego 0.9, DR= 60%
- zanotowano około 8% fałszywych alarmów,

ANALIZA 4


W tym wypadku zbiór uczący składa się z dnia 12.05, a testowi podlegają dzień 5.05. Jest to najwyraźniejszy typ incydentu. Przyjęto najoptymalniejszą architekturę sieci:

- 3 warstwy ukryte po 300 neuronów $N = [300 \ 300 \ 300]$
- Parametry procesu uczenia : $lp = [1 \ 0.05 \ 0.5 \ 1]$
- Liczba epok uczenia: $Te = [300]$


Po raz kolejny przeprowadzono standardowo 4 typy testów:

- TEST A – wszystkie pętle; parametry i, v; standaryzacja
- TEST B – istotne pętle; parametry i, v; standaryzacja
- TEST C – wszystkie pętle; parametry i, v; normalizacja
- TEST D – istotne pętle; parametry i, v; normalizacja

a)



b)




Rysunek 89 Wyniki prawdopodobieństwa incydentu TEST A: a) dla zbioru uczącego 12.05, b) dla zbioru testowego 5.05.


Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydentalne
- dla poziomu alarmowego 0.9, wykryto incydent z bardzo wysoką skutecznością, jedynie kilka cykli (7) zostało niewykrytych,
- zanotowano 1 fałszywy alarm

a)



b)




Rysunek 90 Wyniki prawdopodobieństwa incydentu TEST B: a) dla zbioru uczącego 12.05, b) dla zbioru testowego 5.05.


Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydentalne
- dla poziomu alarmowego 0.9, wykryto incydent z bardzo wysoką skutecznością, jedynie kilka cykli (4) zostało niewykrytych,
- zanotowano 1 fałszywy alarm

a)



b)




Rysunek 91 Wyniki prawdopodobieństwa incydentu TEST C: a) dla zbioru uczącego 12.05, b) dla zbioru testowego 5.05.


Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydentalne
- dla poziomu alarmowego 0.9, wykrywalność cechuje się wysoką skutecznością, jednak wystąpiły problemy z wykryciem początkowych cykli incydentu
- nie zanotowano fałszywych alarmów

a)



b)



Rysunek 92 Wyniki prawdopodobieństwa incydentu TEST D: a) dla zbioru uczącego 12.05, b) dla zbioru testowego 5.05.

Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydentalne
- dla poziomu alarmowego 0.9, wykryto incydent z bardzo wysoką skutecznością, jedynie kilka cykli (4) zostało niewykrytych,
- zanotowano 3 fałszywe alarmy, występujące w bliskim sąsiedztwie cykli incydentalnych, prawdopodobnie będące następstwem incydentu

ANALIZA 5


Ostatnia analiza obejmuje wszystkie dni z incydentami – zbiór uczący 11.05 i 12.05 oraz testowe 5.05, 24.07 i 25.07. Dzięki pozytywnym wynikom z dwóch poprzednich analiz należy spodziewać się skutecznego wykrycia incydentów. Jest to teoretycznie najbardziej dopracowany finalny nauczyciel, który mógłby zarządzać wykrywaniem incydentów na analizowanym skrzyżowaniu. Przyjęto najoptymalniejszą architekturę sieci:

- 3 warstwy ukryte po 300 neuronów **N = [300 300 300]**
- Parametry procesu uczenia : **lp = [1 0.05 0.5 1]**
- Liczba epok uczenia: **Te = [300]**


W procesie weryfikacji jego działania również przeprowadzono standardowo 4 typy testów:

- TEST A – wszystkie pętle; parametry i, v; standaryzacja
- TEST B – istotne pętle; parametry i, v; standaryzacja
- TEST C – wszystkie pętle; parametry i, v; normalizacja
- TEST D – istotne pętle; parametry i, v; normalizacja

a)



b)





Rysunek 93 Wyniki prawdopodobieństwa incydentu TEST A: a) dla zbioru uczącego 11.05+12.05, b) dla zbioru testowego 24.07+25.07+5.05

Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydent istotny z wagą $y=1$ oraz wszystkich cykli identyfikowanych jako incydent mniej istotny z wagą na poziomie z przedziału $y= (0.8, 0.9)$
- Incydent z dnia 24.07, dla poziomu alarmowego 0.6, wykryto z bardzo wysoką skutecznością
- Incydent z dnia 25.07, dla poziomu alarmowego 0.6, wykryto ze słabą około 20% skutecznością, wystąpiły problemy z wykryciem początkowych cykli incydentalnych
- Incydent z dnia 05.05, dla poziomu alarmowego 0.9, wykryto z bardzo wysoką skutecznością
- zanotowano 1 fałszywy alarm

a)






Rysunek 94 Wyniki prawdopodobieństwa incydentu TEST B: a) dla zbioru uczącego 11.05+12.05, b) dla zbioru testowego 24.07+25.07+5.05


Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydent istotny z wagą $y=1$ oraz wszystkich cykli identyfikowanych jako incydent mniej istotny z wagą z przedziału $y=(0.7, 0.8)$
- Incydent z dnia 24.07, dla poziomu alarmowego 0.6, wykryto z bardzo wysoką skutecznością
- Incydent z dnia 25.07, dla poziomu alarmowego 0.6, nie został wykryty - należałoby zmniejszyć poziom alarmowy
- Incydent z dnia 05.05, dla poziomu alarmowego 0.9, wykryto z wysoką skutecznością, aczkolwiek późniejsze cykle kwalifikują się do poziomu o mniejszej istotności
- zanotowano 1 fałszywy alarm

a)



b)




Rysunek 95 Wyniki prawdopodobieństwa incydentu TEST C: a) dla zbioru uczącego 11.05+12.05, b) dla zbioru testowego 24.07+25.07+5.05


Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydent istotny z wagą $y=1$ oraz wszystkich cykli identyfikowanych jako incydent mniej istotny z wagą z przedziału $y=(0.65, 0.85)$
- Incydent z dnia 24.07, dla poziomu alarmowego 0.6, wykryto z bardzo wysoką skutecznością
- Incydent z dnia 25.07, dla poziomu alarmowego 0.6, nie został wykryty - należałoby zmniejszyć poziom alarmowy
- Incydent z dnia 05.05, dla poziomu alarmowego 0.9, wykryto z wysoką skutecznością,
- zanotowano 1 fałszywy alarm

a)



b)



Rysunek 96 Wyniki prawdopodobieństwa incydentu TEST D: a) dla zbioru uczącego 11.05+12.05, b) dla zbioru testowego 24.07+25.07+5.05.

Opis:

- Sieć nauczyła się ze skutecznością 100% wszystkich cykli identyfikowanych jako incydent istotny z wagą $y=1$ oraz wszystkich cykli identyfikowanych jako incydent mniej istotny z wagą z przedziału $y=(0.4, 0.6)$
- Incydent z dnia 24.07, dla poziomu alarmowego 0.6, nie został skutecznie wykryty, paradoksalnie jednak wykryto pierwszy cykl incydentu
- Dla incydentu z dnia 25.07, dla poziomu alarmowego 0.6, zostało wykryte tylko kilka późniejszych cykli incydentalnych
- Incydent z dnia 05.05, dla poziomu alarmowego 0.9, wykryto z wysoką skutecznością,
- zanotowano 1 fałszywy alarm.

Podsumowanie:

Tabela 11. Podsumowanie wyników.

Testy	data	Analiza nr 3				Analiza nr 4				Analiza nr 5			
		A	B	C	D	A	B	C	D	A	B	C	D
detection rate (DR)	24.07	87%	92%	98%	100%					95%	92%	83%	4%
	25.07	51%	60%	72%	76%					17%	0%	0%	13%
	5.05					83%	99%	76%	99%	98%	83%	95%	87%
false alarm rate (FAR)	24.07	0,00%	0,00%	0,00%	0,00%								
	25.07	0,69%	1,03%	39,00%	15,00%					0,06%	0,13%	0,13%	0,25%
	5.05					0,00%	0,00%	0,00%	0,00%				
time to detect (TTD)	24.07	1cykl	1cykl	1cykl	1cykl					1cykl	1cykl	2cykl	1cykl
	25.07	1cykl	1cykl	1cykl	1cykl					17cykl	x	x	23cykl
	5.05					1cykl	1cykl	3cykl	2cykl	1cykl	1cykl	1cykl	1cykl

Patrząc na powyższą tabelę można wyprowadzić szereg wniosków:

- Wykrywalność incydentów jest ściśle związana z jego typem:
 - incydent istotny z 5.05 jest wykrywany z bardzo wysoką skutecznością w każdym teście,
 - incydent z 24.07, pomijając jeden z testów, również jest wykrywany przez sieć z wysoką skutecznością,
 - sieć ma największe problemy z wykryciem incydentu z dnia 25.07, wprawdzie jest przez sieć „wyczuwalny”, ale prawdopodobieństwo rzadko przekracza ustawienie poziomów alarmowych,
- Poziom fałszywych alarmów (pomijając test C i D w analizie nr 3) jest na tak niskim poziomie, że nie powoduje żadnych zakłóceń w poprawnym wykryciu rzeczywistego incydentu.
- Największe powody do optymizmu daje szybkość wykrycia incydentu, niemal w każdym wypadku następuje ona zaraz po pierwszym cyklu pomiarowym (cykl sygnalizacji wahający się od 100 do 120s) co pozwoli użytkownikowi na odpowiednio szybko reakcję.
- Pod kątem układania efektywnego algorytmu najbardziej jest zalecane użycie standaryzacji danych, która wydaje się najstabilniejsza.
- Mały wpływ na wyniki miało ograniczenie ilości danych z pętli, kompleksowe podejście do problemu, przynajmniej w tych badaniach, okazało się wystarczające.


6.2. Skrzyżowanie 10 lutego/Świętojańska.

Pierwszym krokiem w analizie wyników jest sprawdzenie poziomu nauczenia się przez program wzorca (nauczyciela). Wyniki przedstawiono na poniższym wykresie. Wynika z niego, że architektura sieci oraz liczba epok uczenia są wystarczające, aby program poprawnie nauczył się wzorca. Maksymalne różnice pomiędzy wzorcem, a wartością nauczoną są poniżej 0,05. Przyjęto następującą architekturę sieci: $N=[57\ 200\ 200\ 200\ 1]$. Przyjęto 5 warstwową architekturę sieci, przy czym warstwy środkowe (ukryte) będą posiadały po 200 wejść/wyjść. Liczbę epok uczenia ustalono na 300.



Rysunek 97. Różnice pomiędzy wartością oczekiwaną, a wartością nauczoną.

Wykrywanie incydentu 21.04.2015




Rysunek 98. Prawdopodobieństwo incydentu wg. cykli dnia 21.04.2015.

Opis:

- Sieć neuronowa wykrywa incydent ze skutecznością DR=100%.
- Sieć wskazuje na incydent w cyklach 62-121, a wartość prawdopodobieństwa incydentu w tych cyklach wynosi ok. 0,99.
- Zdarzenie zostało wykryte w tym samym cyklu, w którym wystąpiło, tak więc czas do wykrycia zdarzenia zależy od czasu do końca cyklu (30 sekund).
- Liczba fałszywych alarmów w tym dniu (przy założeniu progu incydentalnego na 0,8) wynosi 2.
- Przy zastosowaniu progu alarmowego na 0,6 liczba wskazań wynosi 67 (59 cykli incydentalnych i 8 fałszywych).

Wykrywanie incydentu 13.05.2015




Rysunek 99. Prawdopodobieństwo incydentu wg. cykli dnia 13.05.2015.

Opis:

- Sieć neuronowa wykrywa incydent ze skutecznością DR=76% przy progu alarmowym ustawionym na 0,8. Przy obniżeniu progu do 0,6, DR=88%
- Sieć wskazuje na incydent w cyklach 111-125 (z wyłączeniem cykli 113, 115, 117, 126, których wskaźnik incydentu został określony poniżej 0,8), a wartość prawdopodobieństwa incydentu w tych cyklach wynosi ok. 0,80.
- Zdarzenie zostało wykryte w tym samym cyklu, w którym wystąpiło, tak więc czas do wykrycia zdarzenia zależy od czasu do końca cyklu (40 sekund).
- Liczba fałszywych alarmów w tym dniu (przy założeniu progu incydentalnego na 0,8) wynosi 2.

Wykrywanie incydentu 19.05.2015




Rysunek 100. Prawdopodobieństwo incydentu wg. cykli dnia 19.05.2015.

Opis:

- Sieć neuronowa wykrywa incydent ze skutecznością DR=100%.
- Dodatkowo sieć wskazuje na incydent w cyklach 205-207, czyli 3 cykle dłużej niż zaobserwowane cykle incydentalne podczas analizy wypadków. Wskazuje to na to, że sieć dostrzegła anomalie w ruchu dokładniej niż w przypadku obserwacji wykresów ruchu.
- Zdarzenie zostało wykryte w tym samym cyklu, w którym wystąpiło, tak więc czas do wykrycia zdarzenia zależy od czasu do końca cyklu (20 sekund).
- Liczba fałszywych alarmów w tym dniu (przy założeniu progu incydentalnego na 0,8) wynosi 1.
- Przy zastosowaniu progu alarmowego na 0,6 liczba fałszywych wskazań wynosi 2.

Wykrywanie incydentu 6.03.2015.




Rysunek 101. Prawdopodobieństwo incydentu wg. cykli dnia 6.03.2015.

Opis:

- Sieć neuronowa wykrywa incydent ze skutecznością DR=74%.
- Wykrycie incydentu nastąpiło w następnym cyklu po wystąpieniu zdarzenia.
- Prawdopodobieństwo wypadku w cyklu 16, czyli cyklu wystąpienia, wynosi 0,33.
- Sieć wskazuje na incydent w cyklach 17-38 (z wyłączeniem kilku cykli), a wartość prawdopodobieństwa incydentu w tych cyklach wynosi ok. 0,97.
- Liczba fałszywych alarmów w tym dniu (przy założeniu progu incydentalnego na 0,8) wynosi 3.
- Przy zastosowaniu progu alarmowego na 0,6 liczba fałszywych wskazań wynosi 5.

Wykrywanie incydentu 19.03.2015.




Rysunek 102. Prawdopodobieństwo incydentu wg. cykli dnia 19.03.2015.

Opis:


- Sieć neuronowa wykrywa incydent ze skutecznością DR=83%.
- Wykrycie incydentu nastąpiło w następnym cyklu po wystąpieniu zdarzenia.
- Prawdopodobieństwo wypadku w cyklu 79, czyli cyklu wystąpienia, wynosi 0,31.
- Sieć wskazuje na incydent w cyklach 79-118 (z wyłączeniem kilku cykli), a wartość prawdopodobieństwa incydentu w tych cyklach wynosi ok. 0,94.
- Liczba fałszywych alarmów w tym dniu (przy założeniu progu incydentalnego na 0,8) wynosi 1.
- Przy zastosowaniu progu alarmowego na 0,6 liczba fałszywych wskazań wynosi 1, natomiast DR=90%.

Przykładowe dni bez incydentu


Na wykresach prawdopodobieństwa incydentu pojawiają się sporadyczne fałszywe alarmy. W ciągu badanego okresu 6-21.05 średnia fałszywych alarmów wynosi 4,33/dzień. Sieć dość dobrze radzi sobie z wykrywaniem ruchu nocnego i kwalifikowania go jako bez incydentu. Przy ruchu porannym sieć częściej przypisuje normalny ruch jako incydent, jednakże ich ilość nie jest duża. W związku z tym nie ma potrzeby tworzenia nowego nauczyciela lub zmieniania architektury sieci.



Rysunek 103. Prawdopodobieństwo incydentu wg. cykli dnia 6.05.2015.



Rysunek 104. Prawdopodobieństwo incydentu wg. cykli dnia 12.05.2015.



Rysunek 105. Prawdopodobieństwo incydentu wg. cykli dnia 21.05.2015.

W oparciu o poniższą tabelę oraz wcześniejsze analizy można wysnuć następujące wnioski:

1. Wyniki uczenia są bardzo dobre dla większości cykli nauczyciela.
2. Wykrywalność incydentu jest ściśle związana z typem incydentu. Na ogół incydenty bardziej istotne, których wpływ na ruch na skrzyżowaniu był istotny (anomalie ruchu zauważalne przynajmniej na kilku pętach przez kilka cykli) są wykrywane bardzo dobrze nawet przy progu alarmowym 0,8. Incydenty mniej istotne są również wykrywane, lecz poziom DR jest niesatysfakcjonujący (przynajmniej dla progu alarmowego 0,8).
3. Wskaźnik fałszywych alarmów (FAR) jest na zadowalającym poziomie. Osiąga wartości:

$$FAR_{off}(0,8) = 0.44\%$$

$$FAR_{off}(0,6) = 0.69\%$$

Co oznacza (zakładając cykl trwający 90s), że fałszywy alarm będzie następował co ok. 5,7 godz. dla poziomu alarmowego 0,8 lub co ok. 3,6 godz. Dla poziomu alarmowego 0,6.

4. Czas wykrycia zdarzenia zwykle jest poniżej jednego cyklu. Przy założeniu cyklu sygnalizacyjnego 90s średni czas do wykrycia zdarzenia jest poniżej jednej minuty. Pozwala to na szybką reakcję zarządcy w Centrum Sterowania Ruchem w celu zmniejszenia skutków powstałego incydentu oraz na szybką akcję ratowniczą.

Tabela 12. Podsumowanie wyników skrzyżowanie 10 lutego/Świętojańska.

	Nazwa wskaźnika	Data incydentu					Razem dni incydentalne	Dni bez incydentu
		21.04	13.05	19.05	6.03	19.03		
Próg alarmowy 0.8	DR [%]	100	76	100	74	83	86	
	FAR [%]	0.27	0.27	0.13	0.41	0.69	0.29	0.62
	TTD [min.]	0.5	0.66	0.33	1.5	1.25	0.77	
Próg alarmowy 0.6	DR [%]	100	88	100	83	88	91	
	FAR [%]	1.09	0.41	0.27	0.69	0.69	0.61	0.78
	TTD [min.]	0.5	0.66	0.33	1.5	1.25	0.77	

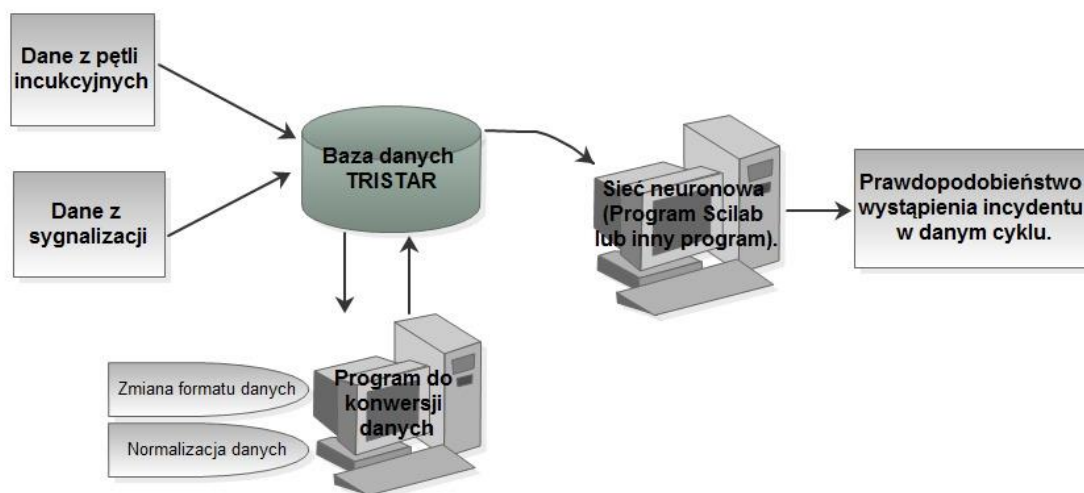
6.3. Zestawienie porównawcze obu skrzyżowań.

Tabela 134. Porównanie analiz obu skrzyżowań

	Morska - Owsiana	10 Lutego - Świętojańska
Cechy incydentów wykorzystywanych w opracowaniu algorytmu	Analiza zróżnicowanych wypadków o większej i mniejszej istotności, zaburzenia zazwyczaj wykrywane przez przynajmniej kilka pętli	Analiza zróżnicowanych wypadków, których wpływ swoim zasięgiem najczęściej obejmuje tylko 1-2 pętli
Sposób podejścia do opracowania algorytmu ze względu na zróżnicowane nateżenie ruchu na skrzyżowaniach	Główny potok ruchu skumulowany na ulicy Morskiej	Zróżnicowany ruch we wszystkich kierunkach
	↓	↓
	Sprawdzenie wpływu ograniczenia liczby analizowanych pętli tylko do tych umiejscowionych na głównym potoku ruchu	Kompleksowa analiza tylko dla wszystkich pętli
Sposób przetworzenia danych	Standaryzacja i normalizacja min-max	normalizacja min-max
Metodologia podejścia	Zastosowanie połączenia podejścia postępującego z porównującym - sprawdzenie zależności pomiędzy incydentami, stosowanie kolejnych kroków mających na celu usprawnienie utworzonego algorytmu, wybór różnych rozwiązań zbiorów uczących i ich porównanie,	Zastosowanie podejścia korygującego - stworzenie bazowego algorytmu, korygowanie jego działania oraz postępowe ulepszanie nauczyciela w celu zmniejszenia poziomu FAR
Wyniki uczenia	Opracowanie wielu zbiorów uczących, w większości wyniki uczenia bardzo dobre	Bardzo dobre dla finalnego nauczyciela
Poziom progów alarmowych	od 0,6 dla incydentów mniej istotnych do 0,9 dla incydentów bardziej istotnych	0,7-0,9 dla jednego typu incydentów
Wyniki wykrywalności	od 83% do 96% (w zależności od sposobu)	86,39%
Falszywe alarmy	0,1 - 1%	0,46%
Średnie czasy potrzebne do wykrycia	~1cykl	0,87 min/~1cykl

Porównując obie metody podejścia oraz uzyskane dzięki nim wyniki można wnioskować, że w obu przypadkach zastosowanie algorytmu wykorzystujące sztuczne sieci neuronowe ma sens. Stworzenie jednak odpowiedniego i skutecznego sposobu wymaga szczegółowej analizy przeróżnych czynników, zarówno na etapie przedwstępnym, czyli od samej informacji o skrzyżowaniu i jego charakterystyce, aż do etapu zaawansowanych prac nad sposobem działania samej sieci i determinującego wykrycie zbioru uczącego. Głównym wnioskiem płynącym z tych badań jest to, że nie ma możliwości stworzenia jednego algorytmu, którego można by zastosować do każdego typu skrzyżowań. Możliwe jest jednak zastosowanie tego samego algorytmu dla skrzyżowań o podobnej charakterystyce. Dla poprawnego działania tego sposobu wykrywania należy indywidualnie zbadać każde skrzyżowanie i wykonać szereg testów, które pozwolą wybrać najlepszy z nich.

6.4. Propozycja działania systemu wykrywania incydentów w czasie rzeczywistym.



Rysunek 106. Uproszczony schemat działania systemu wykrywania incydentów w czasie rzeczywistym.

Powyżej przedstawiono koncepcje działania systemu w czasie rzeczywistym. W tym podejściu dane z pętli indukcyjnych oraz dane z sygnalizacji przesyłane byłyby bezprzewodowo na serwer systemu Tristar. W specjalnej bazie danych przygotowanej na tym serwerze zapisywane byłyby dane ze wszystkich skrzyżowań objętych systemem w ciągu jednego pełnego cyklu sygnalizacyjnego. Po zakończeniu cyklu zebrane dane byłyby przekazywane do osobnego programu (modułu) i poddane transformacji do formatu wymaganego do wprowadzenia na sieć neuronową. Proponowany przez autorów format danych jest następujący:

- Liczba porządkowa cyklu lub czas rozpoczęcia cyklu (ID,czas) – kolumna mająca ułatwić lokalizację danego wiersza w ciągu dnia, jest ona konieczna, aby sieć neuronowa mogła rozpoznać np. porę dnia,
- Liczba wzbudzeń danej pętli na minutę danego cyklu (ile)– dla wszystkich pętli na danym skrzyżowaniu osobna kolumna,
- Średnia prędkość pojazdów w cyklu (V) – dla wszystkich pętli na danym skrzyżowaniu osobna kolumna,
- Średni czas nad pętlą pomiarową w cyklu (T) – dla wszystkich pętli na danym skrzyżowaniu osobna kolumna,
- Średnia odległość od poprzedniego pojazdu w cyklu (D) – dla wszystkich pętli na danym skrzyżowaniu osobna kolumna,

Kwestią kolejnych badań może być wprowadzenie dodatkowych kolumn: Δile , ΔV , ΔT , ΔD , które mówiłyby o zmianie opisanych wyżej parametrów w stosunku do poprzedniego cyklu. Należałoby zbadać, czy dane te mogłyby wpłynąć na poprawę działania algorytmu oraz

zwiększenie wykrywalności incydentów (DR) przy jednoczesnym spadku fałszywych alarmów (FAR).

Następnie dane zostałyby poddane normalizacji. Wartości graniczne potrzebne podczas tego procesu mogłyby być ustalone w oparciu o dane np. z dnia poprzedniego. Po tym procesie dane wracałyby na serwer Tristar do osobnego segmentu i gromadzone w bazie danych w celu dalszych ulepszeń systemu oraz późniejszej analizy danych i ulepszania nauczyciela. Z bazy systemu Tristar dane następnie wysyłano by do programu Scilab lub innego programu pracującego z sieciami neuronowymi. W programie tym zaimplementowany byłby nauczyciel, który mógłby być stopniowo ulepszany. Na przykład raz w tygodniu przeprowadzana byłaby analiza fałszywych wskazań algorytmu w celu ich eliminacji i poprawy nauczyciela. Sieć neuronowa jako wynik wskazywałaby prawdopodobieństwo wystąpienia incydentu na danym skrzyżowaniu w danym cyklu sygnalizacyjnym. Operator systemu otrzymywałby wartości wygenerowane przez program i na bieżąco analizowałby jego wskazania oraz reagował w razie wygenerowania wartości alarmowej.

Podsumowanie.

Niniejsza praca przedstawia sposób tworzenia algorytmu wykrywania incydentów na skrzyżowaniu. Badania oparto na dwóch skrzyżowaniach w Gdyni : Morska/Owsiana oraz 10 lutego/Świętojańska, które są włączone do systemu Tristar. Skrzyżowania te są kompleksowo wyposażone w podwójne pętle indukcyjne (na każdym pasie ruchu znajduje się para pętli), które rejestrują ruch na skrzyżowaniach za pomocą parametrów: czas wzbudzenia, prędkość pojazdu, czas nad punktem, dystans od poprzedniego pojazdu i inne. Dane te posłużyły autorom pracy do zbudowania modelu.

Pierwszym etapem prac była analiza literatury. Przeanalizowano badania dotyczące wykrywania incydentów ze szczególnym naciskiem na te algorytmy, które wykorzystywały pętle indukcyjne. Następnie przestudiowano znalezione w literaturze gotowe algorytmy. Niestety większość z nich dotyczyła dróg ekspresowych i autostrad. Jeśli algorytm dotyczył wykrywania incydentów w miastach najczęściej był oparty tylko na danych laboratoryjnych. Mimo wszystko zdobyto podpowiedzi do budowy algorytmu. Przegląd literatury wykazał również, że nie da się zastosować takich samych algorytmów wykrywania incydentów dla wszystkich skrzyżowań dlatego do każdego przypadku należy podejść indywidualnie.

Kolejnym etapem była transformacja danych z systemu Tristar do formatu użytecznego podczas budowy algorytmu wykrywania incydentów z wykorzystaniem sieci neuronowych. Postanowiono badać ruch na skrzyżowaniu w ramach jednego cyklu. Podział taki daje duże prawdopodobieństwo uzyskania satysfakcjonujących wyników przy stosunkowo krótkim czasie wykrycia zdarzenia. Przyjęcie krótszego okresu czasu mogłoby powodować trudności w poprawnym działaniu algorytmu. Dane przekonwertowano za pomocą programu napisanego przez autorów w języku PHP/SQL, a następnie poddano je normalizacji oraz standaryzacji. Po przygotowaniu danych wykonano analizę w klasyfikatorze programu R. Dawała ona odpowiedź czy dany układ ma szansę zwrócenia satysfakcjonujących wyników po wprowadzeniu danych do sieci neuronowej. Zarówno w przypadku skrzyżowania Morska/Owsiana, jak i 10 lutego/Świętojańska uzyskano bardzo dobre wyniki klasyfikacji. Większość incydentów została sklasyfikowana w osobnej grupie, co wskazywało na to, że anomalie w ruchu na skrzyżowaniu mogą być również widoczne dla sieci neuronowych przy zastosowanym formacie danych.

Ostatnim etapem było sprawdzenie algorytmu sieci neuronowych w wykrywaniu rzeczywistych incydentów. Do tego celu wykorzystano algorytm napisany w programie Scilab. Głównym problemem w tworzeniu sieci neuronowej było stworzenie odpowiedniego nauczyciela, który pozwalałby na wykrycie incydentów. Zadanie to zrealizowano w dwojaki sposób, zależny od skrzyżowania. W przypadku skrzyżowania Morska/Owsiana zastosowano podejście postępująco - porównujące. Sprawdzano zależności pomiędzy incydentami i wprowadzano kolejne kroki mające na celu usprawnienie tworzonego algorytmu dla różnych rozwiązań

zbiorów uczących. W przypadku skrzyżowania 10 lutego/Świętojańska zastosowano podejście korygujące. Stworzono bazowy algorytm, którego działanie było korygowane, co prowadziło do ulepszania nauczyciela i zmniejszania poziomu fałszywych alarmów (FAR) przy jednoczesnym zwiększeniu wykrywalności incydentów (DR).

Otrzymane rezultaty dają podstawy do optymizmu. W przypadku najlepszej konfiguracji sieci neuronowej uzyskano bardzo dobre wyniki zarówno dla skrzyżowania Morsk/Owsiana, jak i 10 lutego/Świętojańska. W przypadku tego pierwszego skrzyżowania sieć w każdym z podejść sieć dobrze radzi sobie z wykrywaniem incydentów 24.07 i 5.05. Poziom wykrycia jest powyżej 95% przy poziomie fałszywych alarmów FAR=0,06%. Gorzej sieć radzi sobie z wykryciem incydentu 25.07 (w pracy wyjaśnione są przyczyny słabego wykrywania tegoż incydentu). Przy podejściu globalnym uzyskano tylko DR=17%, przy podejściu lokalnym wskaźnik DR=76%, jednak przy bardzo dużym procencie fałszywych alarmów FAR=15%.

Natomiast dla skrzyżowania 10 lutego/Świętojańska uzyskano wyniki, które dają podstawy do możliwości wprowadzenia stworzonego algorytmu w rzeczywistym działaniu. Uzyskano wysoki wskaźnik wykrycia na tym skrzyżowaniu równy 86% przy poziomie alarmowym ustawionym na 0,8. Poziom fałszywych alarmów wynosił 0,44% co odpowiada jednemu fałszywemu zgłoszeniu co ok. 6 godzin. W przypadku ustawienia progu alarmowego na 0,6 poziom wykrycia DR wzrasta do 91% przy poziomie FAR=0,69% (1 fałszywy alarm co ok. 4 godz.).

Niniejsza praca została napisana w związku z planowanym wprowadzeniem modułu wykrywania incydentów w sieci drogowej miasta Gdynia, który ma być częścią wprowadzonego w tym mieście systemu Tristar. Algorytm wykrywania incydentów w takim przypadku musiałby działać w czasie rzeczywistym. Zastosowany przez autorów projekt algorytmu przy wykorzystaniu odpowiedniej struktury sprzętowej może być wprowadzony w rzeczywistym układzie drogowym. Jeżeli system miałby objąć większą liczbę skrzyżowań konieczna jest dokładna analiza tychże skrzyżowań oraz zebranie danych dotyczących incydentów na nich.

Literatura.

1. Dia H. , Thomas K, Development and evaluation of arterial incident detection models using fusion of simulated probe vehicle and loop detector data, The University of Queensland, Brisbane, 2011.
2. Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Biocybernetyka i inżynieria biomedyczna 2000, tom 6 - Sieci neuronowe, Polska Akademia Nauk, Warszawa 2000.
3. Kaszubowski D., Oskarbski J., Symulacja procesu wyboru metody wykrywania zdarzeń drogowych, Logistyka 3 2012.
4. Khan S. I., Ritchie S. G.: Statistical and neural classifiers to detect traffic operational problems on urban arterials, Transportation Research Part C 6 (1998) 291 – 314.
5. Krzanowski W. J.: Principles of Multivariate Analysis: A User's Perspective, Oxford University Press, 2000.
6. Martin T. M., Perrin J., Hansen B.: Incident Detection Algorithm Evaluation, University of Utah 2001, <http://www.mountain-plains.org/pubs/pdf/MPC01-122.pdf> (data dostępu 20.08.2015).
7. Oskarbski J.: Problemy automatycznego wykrywania zdarzeń drogowych na sieci ulic – przykład Trójmiasta, Politechnika Gdańska, GAMBIT 2014
8. Oskarbski J.: Wykrywanie zdarzeń drogowych z wykorzystaniem telematyki transportu, Logistyka 6/2011
9. Oskarbski J., Miszewski M., Zawisza M., Żarski K.: Zasilanie modeli systemów transportowych danymi z systemu zarządzania ruchem, IV Ogólnopolska Konferencja Naukowo-Techniczna Modelowanie podróży i prognozowanie ruchu – Modelling, Kraków 2014
10. Ozbay K., Kachroo P.: Incident Management in Intelligent Transportation Systems, Artech House, Inc., 685 Canton Street, Norwood MA 02062 1999.
11. Persaud Bhagwant N., Hall F.; Hall L. M.: Congestion Identification Aspects of the McMaster Incident Detection Algorithm. Transportation Research Record 1287(167-175) 1990.
12. Saka A., Introduction to Intelligent Transportation Systems, Consortium for ITS Training and Education (CITE) Module, 2000.
13. Stencel M.: Wybrane zagadnienia pomiarów parametrów ruchu drogowego za pomocą wiroprowadowych, indukcyjnych czujników pętlowych, ITS – Przegląd, wrzesień 2015,

14. System Monitorowania i Nadzoru Ruchu Pojazdów,
<http://www.mobilnagdynamia.pl/tristar/233-o-systemie-tristar-system-monitorowania-i-nadzoru-ruchu-pojazdow> (data dostępu 20.08.2015)
15. System Sterowania Ruchem Drogowym, <http://www.mobilnagdynamia.pl/tristar/229-o-systemie-tristar-system-sterowania-ruchem-drogowym> (data dostępu 20.08.2015)
16. System Zarządzania Bezpieczeństwem Ruchu,
<http://www.mobilnagdynamia.pl/tristar/252-o-systemie-tristar-system-zarzadzania-bezpieczenstwem-ruchu> (data dostępu 20.08.2015)
17. Tadeusiewicz R.: Elementarne wprowadzenie do sieci neuronowych z przykładowymi programami, Akademicka Oficyna Wydawnicza, Warszawa, 1998.
18. Wawrzonek T.: Zintegrowany System Zarządzania Ruchem - TRISTAR, ITS – Przegląd, wrzesień 2015,
19. www.google.com/maps

Spis tabel.

Tabela 1. Wyniki wskaźników wykrywania dla poszczególnych algorytmów [2].	28
Tabela 2. Wykrywalność w zależności od ilości blokowanych pasów ruchu.....	33
Tabela 3. Identyfikacja numerów pętli na skrzyżowaniu.	49
Tabela 4. Pętle indukcyjne na skrzyżowaniu ul. 10 lutego i ul. Świętojańskiej.....	52
Tabela 5. Anomalie w odczytach poszczególnych pętli dnia 5.05.2015.	53
Tabela 6. Anomalie w odczytach poszczególnych pętli dnia 24.07.2014.	55
Tabela 7. Anomalie w odczytach poszczególnych pętli dnia 25.07.2014.	57
Tabela 8. Anomalie w odczytach poszczególnych pętli dnia 11.05.2015.	59
Tabela 9. Anomalie w odczytach poszczególnych pętli dnia 11.05.2015.	60
Tabela 10. Anomalie na pętlach indukcyjnych podczas wypadku 19.03.2015.....	68
Tabela 12. Podsumowanie wyników.	108
Tabela 13. Podsumowanie wyników skrzyżowanie 10 lutego/Świętojańska.	115
Tabela 14. Porównanie analiz obu skrzyżowań	116

Spis rysunków.

Rysunek 1. Pętla indukcyjna na jednym ze skrzyżowań [15].	15
Rysunek 2. Ilustracja zjawiska powstawania prądów wirowych [13].	16
Rysunek 3. Układ pomiarowy do zliczania pojazdów (Cz. P. – czujnik; UK – układ kondycjonowania sygnału; μ P – system mikroprocesorowy; IK – interfejsy telekomunikacyjne; RTC – zegar czasu rzeczywistego) [13].	17
Rysunek 4. Analogowy sygnał profilu magnetycznego i odpowiadający mu sygnał cyfrowy obecności pojazdu [13].	17
Rysunek 5. Układ pomiaru prędkości za pomocą dwóch czujników pętlowych (Cz. P. – czujnik; UK1,2 – układy kondycjonowania sygnału; μ P – system mikroprocesorowy; IK – interfejsy telekomunikacyjne; RTC – zegar czasu rzeczywistego) [13].	18
Rysunek 6. Zależności czasowe sygnałów generowanych przez pojazd podczas pomiaru prędkości za pomocą dwóch czujników pętlowych [13].	18
Rysunek 7. Zależność DR/FAR [1].	20
Rysunek 8. Model złożonego systemu, możliwy do realizacji w postaci sieci neuronowych.	21
Rysunek 9. Schematyczna budowa typowej sieci neuronowej [2].	22
Rysunek 10. Istota metody zmiany wektora wag podczas procesu uczenia sieci [2].	23
Rysunek 11. Modułowa sieć neuronowa [1].	29
Rysunek 12. Konfiguracje detektorów w modelu Dia i Thomasa [1].	30
Rysunek 13. Analizowana sieć Los Angeles z lokalizacją pętli indukcyjnych [4].	32
Rysunek 14. Zależność DR od FAR dla wybranych dwóch konfiguracji [4].	34
Rysunek 15. Porównanie wykrywalności sieci modularnej z pojedynczą siecią MLF [4].	34
Rysunek 16. Schemat blokowy podejścia zastosowanego przez autorów.	35
Rysunek 17. Współpraca baz danych w systemie TRISTAR [9].	37
Rysunek 18. Format danych dotyczący stanów na pętlach indukcyjnych.	38
Rysunek 19. Format danych dotyczący stanów sygnalizacji.	39
Rysunek 20. Tabela bazy danych (Lista_skr).	41
Rysunek 21. Tabela bazy danych (Lista_petli).	41
Rysunek 22. Tabela bazy danych (Incydent_XX_XX_XX_sygnal).	42
Rysunek 23. Tabela bazy danych (Incydent_XX_XX_XX_petle).	43
Rysunek 24. Relacje między tabelami.	44
Rysunek 25. Struktura tabeli wynikowej z danymi wprowadzanymi do sieci neuronowej.	44
Rysunek 26. Kody programu php/sql dotyczące łączenia z bazą danych, ustalenia czasu początkowego cykli oraz liczby pętli na skrzyżowaniu.	45
Rysunek 27. Pobieranie danych z bazy danych.	46
Rysunek 28. Schemat skrzyżowania Morska-Owsiana [19].	47
Rysunek 29. Schemat rozmieszczenia pętli (źr. baza TRISTAR).	48
Rysunek 30. Skrzyżowanie ul. 10 lutego z ul. Świętojańską [19].	50
Rysunek 31. Rozmieszczenie pętli indukcyjnych na skrzyżowaniu [Tristar].	51
Rysunek 32. Oznaczone miejsce incydentu z dnia 05.05.	53
Rysunek 33. Odczyty z pętli nr 13 w dniu 5.05.2015 wraz z oznaczonym momentem incydentu:	54
Rysunek 34. Odczyty z pętli nr 0 w dniu 5.05.2015 wraz z oznaczonym momentem incydentu:	54
Rysunek 35. Oznaczone miejsce incydentu z dnia 24.07.2014.	55
Rysunek 36. Odczyty z pętli nr 5 w dniu 24.07.2014 wraz z oznaczonym momentem incydentu:	56
Rysunek 37. Odczyty z pętli nr 14 w dniu 24.07.2014 wraz z oznaczonym momentem incydentu:	56
Rysunek 38. Oznaczone miejsce incydentu z dnia 25.07.2014	57

Rysunek 39. Odczyty z pętli nr 1 w dniu 25.07.2014 wraz z oznaczonym momentem incydentu:	58
Rysunek 40. Oznaczone miejsce symulacji incydentu z dnia 11.05.2015.	59
Rysunek 41. Odczyty z pętli nr 5 w dniu 11.05.2015 wraz z oznaczonym momentem incydentu:	59
Rysunek 42. Oznaczone miejsce symulacji incydentu z dnia 12.05.2015.	60
Rysunek 43. Odczyty z pętli nr 1 w dniu 12.05.2015 wraz z oznaczonym momentem incydentu:	61
Rysunek 44. Reprezentacja graficzna incydentu 21.04.2015.	62
Rysunek 45. Odczyty z pętli nr 3 w dniu 21.04.2015 wraz z oznaczonym momentem incydentu:	62
Rysunek 46. Incydent 13.05.2015.	63
Rysunek 47. Odczyty z pętli nr 8 w dniu 13.05.2015 wraz z oznaczonym momentem incydentu:	64
Rysunek 48. Incydent 19.05.2015.	64
Rysunek 49. Odczyty z pętli nr 10 w dniu 19.05.2015 wraz z oznaczonym momentem incydentu:	65
Rysunek 50. Odczyty z pętli nr 11 w dniu 19.05.2015 wraz z oznaczonym momentem incydentu:	65
Rysunek 51. Odczyty z pętli nr 6 w dniu 19.05.2015 wraz z oznaczonym momentem incydentu:	65
Rysunek 52. Incydent 6.03.2015.	66
Rysunek 53. Odczyty z pętli nr 1 w dniu 6.03.2015 wraz z oznaczonym momentem incydentu:	67
Rysunek 54. Incydent 19.03.2015.	67
Rysunek 55. Cluster means.	69
Rysunek 56. Uproszczony schemat dotyczący sposobu analizy danych w środowisku R.	70
Rysunek 57. Wektor klastrowy 4-grupowo - dzień 5.05, etap 1.	71
Rysunek 58. Wektor klastrowy 4-grupowo - dzień 5.05, etap 2.	71
Rysunek 59. Wektor klastrowy 4-grupowo - dzień 5.05, etap 3.	72
Rysunek 60. Wektor klastrowy 4-grupowo - dzień 5.05, etap 4.	72
Rysunek 61. Wektor klastrowy 4-grupowo - dzień 24.07, etap 1.	73
Rysunek 62. Wektor klastrowy 4-grupowo - dzień 24.07, etap 2.	73
Rysunek 63. Wektor klastrowy 4-grupowo - dzień 24.07, etap 3.	74
Rysunek 64. Wektor klastrowy 4-grupowo - dzień 24.07, etap 4.	74
Rysunek 65. Wektor klastrowy 4-grupowo - dzień 25.07, etap 1.	75
Rysunek 66. Wektor klastrowy 4-grupowo - dzień 25.07, etap 2.	76
Rysunek 67. Wektor klastrowy 4-grupowo - dzień 25.07, etap 3.	76
Rysunek 68. Wektor klastrowy 4-grupowo - dzień 25.07, etap 4.	77
Rysunek 69. Podział na 6 clusters dnia 21.04.2015 w programie R.	79
Rysunek 70. Podział na 9 clusters dnia 13.05.2015 w programie R.	80
Rysunek 71. Podział na 7 clusters dnia 19.05.2015 w programie R.	80
Rysunek 72. Podział na 4 clusters dnia 6.03.2015 w programie R.	81
Rysunek 73. Podział na 7 clusters dnia 6.03.2015 w programie R.	81
Rysunek 74. Podział na 2 clusters dnia 19.03.2015 w programie R.	81
Rysunek 75. Podział na 7 clusters dnia bez incydentu 6.05.2015 w programie R.	82
Rysunek 76. Podział na 7 clusters dnia bez incydentu 12.05.2015 w programie R.	82
Rysunek 77. Fragment wyników analizy PCA.	85
Rysunek 78. Analiza PCA - wektoryzacja parametrów dla wybranych cykli.	86
Rysunek 79. Kod w programie Scilab®, poznanie nauczyciela.	87
Rysunek 80. Element skryptu – a) standaryzacja, b) normalizacja.	88
Rysunek 81. Kod w programie Scilab, wykrywanie incydentów.	88

Rysunek 82. Uproszczony schemat procesu analizy skrzyżowania MORSKA-OWSIANA (opr. własne)	89
Rysunek 83 Wektoryzacja incydentów z oznaczoną chmurą punktów z incydemem (normalizacja lokalna): a) 24.07, b) 25.07.....	92
Rysunek 84. Wektoryzacja incydentów z oznaczoną chmurą punktów z incydemem (24.07 – czarny, 25.07 – czerwony) w normalizacji globalnej.....	92
Rysunek 85. Wyniki prawdopodobieństwa incydemu TEST A: a) dla zbioru uczącego 11.05, b) dla zbioru testowego 24.07, c) dla zbioru testowego 25.07.	94
Rysunek 86. Wyniki prawdopodobieństwa incydemu TEST B: a) dla zbioru uczącego 11.05, b) dla zbioru testowego 24.07, c) dla zbioru testowego 25.07.	95
Rysunek 87. Wyniki prawdopodobieństwa incydemu TEST C: a) dla zbioru uczącego 11.05, b) dla zbioru testowego 24.07, c) dla zbioru testowego 25.07.	97
Rysunek 88. Wyniki prawdopodobieństwa incydemu TEST A: a) dla zbioru uczącego 11.05, b) dla zbioru testowego 24.07, c) dla zbioru testowego 25.07.	98
Rysunek 89 Wyniki prawdopodobieństwa incydemu TEST A: a) dla zbioru uczącego 12.05, b) dla zbioru testowego 5.05.	99
Rysunek 90 Wyniki prawdopodobieństwa incydemu TEST B: a) dla zbioru uczącego 12.05, b) dla zbioru testowego 5.05.	100
Rysunek 91 Wyniki prawdopodobieństwa incydemu TEST C: a) dla zbioru uczącego 12.05, b) dla zbioru testowego 5.05.	101
Rysunek 92 Wyniki prawdopodobieństwa incydemu TEST D: a) dla zbioru uczącego 12.05, b) dla zbioru testowego 5.05.	102
Rysunek 93 Wyniki prawdopodobieństwa incydemu TEST A: a) dla zbioru uczącego 11.05+12.05, b) dla zbioru testowego 24.07+25.07+5.05.....	104
Rysunek 94 Wyniki prawdopodobieństwa incydemu TEST B: a) dla zbioru uczącego 11.05+12.05, b) dla zbioru testowego 24.07+25.07+5.05.....	105
Rysunek 95 Wyniki prawdopodobieństwa incydemu TEST C: a) dla zbioru uczącego 11.05+12.05, b) dla zbioru testowego 24.07+25.07+5.05.....	106
Rysunek 96 Wyniki prawdopodobieństwa incydemu TEST D: a) dla zbioru uczącego 11.05+12.05, b) dla zbioru testowego 24.07+25.07+5.05.....	107
Rysunek 97. Różnice pomiędzy wartością oczekiwaną, a wartością nauczoną.	109
Rysunek 98. Prawdopodobieństwo incydemu wg. cykli dnia 21.04.2015.....	109
Rysunek 99. Prawdopodobieństwo incydemu wg. cykli dnia 13.05.2015.....	110
Rysunek 100. Prawdopodobieństwo incydemu wg. cykli dnia 19.05.2015.....	111
Rysunek 101. Prawdopodobieństwo incydemu wg. cykli dnia 6.03.2015.....	112
Rysunek 102. Prawdopodobieństwo incydemu wg. cykli dnia 19.03.2015.....	112
Rysunek 103. Prawdopodobieństwo incydemu wg. cykli dnia 6.05.2015.....	113
Rysunek 104. Prawdopodobieństwo incydemu wg. cykli dnia 12.05.2015.....	114
Rysunek 105. Prawdopodobieństwo incydemu wg. cykli dnia 21.05.2015.....	114
Rysunek 106. Uproszczony schemat działania systemu wykrywania incydemów w czasie rzeczywistym.	117