



**Akustyczna analiza parametrów ruchu drogowego
z wykorzystaniem informacji o hałasie oraz uczenia maszynowego**

autor: **mgr inż. Karolina Małgorzata Marciniuk**

Promotor: **prof. dr hab. inż. Bożena Kostek, prof. ZW PG**

Rozprawa doktorska w dyscyplinie
Telekomunikacja

Politechnika Gdańska
Wydział Elektroniki, Telekomunikacji i Informatyki
Gdańsk, 2018

Streszczenie

Celem rozprawy było opracowanie akustycznej metody analizy parametrów ruchu drogowego. Zasada działania akustycznej analizy ruchu drogowego zapewnia pasywną metodę monitorowania natężenia ruchu.

W pracy przedstawiono wybrane metody uczenia maszynowego w kontekście analizy dźwięku (ang. *Machine Hearing*). Przedstawiono metodologię klasyfikacji zdarzeń w ruchu drogowym z wykorzystaniem uczenia maszynowego. Przybliżono podstawowe zagadnienia z dziedziny Inżynierii Ruchu Drogowego, skupiając się na parametrach oceny strumienia ruchu i ich metodach pomiaru w kontekście dynamicznego zarządzania ruchem. W celu realizacji badań zarejestrowano sesje nagrań fonicznych w różnych warunkach pogodowych i w różnych porach roku. W przeprowadzonych badaniach, na podstawie rejestrowanych poziomów hałasu, wyznaczano liczbę pojazdów, czasy zdarzenia i zajętości przekroju drogi w dziedzinie czasu. Na podstawie zebranych danych dokonywano statystyk dla zadanych przedziałów czasu. Klasyfikacja aktywnych ramek sygnału, pozwala na rozpoznawanie typu pojazdu i warunków meteorologicznych panujących na drodze.

Przebadano skuteczność działania wybranych algorytmów, w tym uczenia głębokiego w zestawieniu z komercyjnymi urządzeniami wykorzystywanymi w ocenie ruchu drogowego, uzyskując zbliżone skuteczności. Uzyskane wyniki wskazują na możliwość wykorzystania zaproponowanej metodologii w praktycznych rozwiązaniach nadzoru ruchu drogowego.

Abstract

The purpose of the dissertation was to develop an acoustic method for analyzing traffic parameters. The principle of the acoustic traffic analysis provides a passive method of traffic monitoring. This thesis presents selected methods of machine learning in the context of sound analysis (*Machine Hearing*). The methodology for classifying events in road traffic using machine learning is proposed and thoroughly presented. Some chosen issues in the field of Road Traffic Engineering were discussed with a focus on the parameters of the traffic flow assessment and their measurement methods in the context of dynamic traffic management. In order to carry out the tests, audio recordings were prepared in various weather conditions and at different seasons of the year.

In the conducted tests, based on the registered noise levels, the number of vehicles, event occurrence and road section occupancy in the time domain were determined. Based on the collected data, statistics for the given time intervals were made. Classification of active signal frames allows for recognizing the type of vehicle and meteorological conditions prevailing on the road.

The effectiveness of the selected algorithms was tested, including deep learning, in combination with commercial devices employed in road traffic measurements, achieving similar efficiencies. The obtained results indicate the possibility of using the proposed methodology in practical solutions of traffic management.

Acknowledgement

Realizacja pracy była wspierana przez grant INPREDO *Dobór dopuszczalnych prędkości ruchu na drogach z uwzględnieniem dynamicznego zarządzania ruchem*. Opracowywany przez konsorcjum AHG WSTK i PG w latach 2014-2018. Badania zostały dofinansowane przez Narodowe Centrum Badań i Rozwoju oraz Generalną Dyрекcję Dróg i Autostrad w ramach grantu nr OT4-4B / AGH-PG-WSTKT.

Podziękowania

Pragnę serdecznie podziękować Pani Profesor Bożenie Kostek za poświęcony czas, wsparcie merytoryczne, nieustającą wiarę w moje umiejętności i zaufanie.

Kierownikowi Katedry, Profesorowi Andrzejowi Czyżewskiemu za możliwość pracy w projektach ściśle związanych z moją dziedziną zainteresowań, które niezmiernie przyczyniły się to realizacji niniejszej rozprawy.

Dziękuję pracownikom KSM i Przyjaciółom za kibicowanie i wsparcie. Bez Was napisanie niniejszej pracy byłoby niemożliwe.

Podziękowania dla Gdańskiego Oddziału Zarządu Dróg i Zieleni oraz Gdańskiego Oddziału Generalnej Dyrekcji Dróg Krajowych i Autostrad za pomoc w bezpiecznej realizacji badań terenowych.

Spis oznaczeń i skrótów

<i>ACA</i>	Audio Content Analysis (Analiza zawartości w sygnale fonicznym)
<i>ACC</i>	Accuracy (jakość klasyfikacji)
<i>ACF</i>	Autocorrelation Function (Funkcja autokorelacji)
<i>ASC</i>	Audio Spectrum Centroid (Środek ciężkości widma)
<i>ANN</i>	Artificial Neural Network (Sztuczne sieci neuronowe)
<i>ASR</i>	Automatic Speech Recognition (Automatyczne rozpoznawanie mowy)
<i>ATM</i>	Automatic Traffic Management (Automatyczne zarządzanie ruchem drogowym)
<i>ATR</i>	Automatic Traffic Recorder (Automatyczny zapis rejestrator ruchu drogowego)
<i>BLE</i>	Bluetooth Low Energy (Protokół połączenia Bluetooth z małym poborem mocy)
<i>CA</i>	Computer audition (CA); Computer listening (Słyszenie maszynowe)
<i>CASA</i>	Computational Auditory Scene Analysis (Algorytmiczna analiza sceny dźwiękowej)
<i>CNN</i>	Convolutional Neural Network (Splotowe sieci neuronowe)
<i>DCF</i>	Discrete Cosine Transform (Dyskretna analiza kosinusowa)
<i>DFT</i>	Discrete Fourier Transform (Dyskretna transformacja Fouriera)
<i>DNN</i>	Deep Neural Network (Głębokie uczenie)
<i>ERR</i>	Error rate (poziom błąd)
<i>F0</i>	częstotliwość podstawowa
<i>FHWA</i>	Federal Highway Administration (Federalny (amerykański) Urząd ds ruchu drogowego)
<i>FFT</i>	Fast Fourier Transform (Szybka transformacja Fouriera)

<i>FN</i>	False Negative (falszywie negatywna)
<i>FP</i>	False Positive (falszywie pozytywna)
<i>FVG</i>	Feature Vector Generator (Generator parametrów wektora cech)
<i>GDDKiA</i>	Generalna Dyrekcja Dróg Krajowych i Autostrad
<i>GMM</i>	Gaussian Mixture Model (Liniowa kombinacja rozkładów Gaussa)
<i>HMM</i>	Hidden Markov Model (Ukryte Modele Markowa)
<i>HCM</i>	Highway Capability Model (Model przepustowości autostrad)
<i>IRD</i>	Inżynieria ruchu drogowego
<i>ITS</i>	Intelligent Transportation Systems (Inteligentne systemy transportowe)
<i>kNN</i>	K-Nearest Neighbor (metoda k-najbliższych sąsiadów)
<i>LDA</i>	Linear Discriminant Analysis (Liniowa analiza dyskryminacyjna)
<i>LP</i>	Linear Prediction (Predykcja liniowa)
<i>LPA</i>	Linear Prediction Analysis (Liniowa analiza predykcyjna)
<i>LPC</i>	Linear Predictive Analysis (Analiza liniowo-predykcyjna)
<i>MFCC</i>	Mel Frequency Cepstrum Coefficients (Współczynniki mel-cepstralne)
<i>MIR</i>	Music Information Retrieval (Wyszukiwanie informacji muzycznej)
<i>PAD</i>	Passive Acoustic Detector (Pasywny detektor akustyczny)
<i>PCA</i>	Principal Component Analysis (Analiza głównych składowych)
<i>PPV</i>	Precision, Positive Predictive Value (precyzja)
<i>PSR</i>	Poziom Swobody Ruchu
<i>SCATS</i>	Sydney Coordinated Adaptive Traffic System (Australijski adaptacyjny system sterowania ruchem)
<i>SDR</i>	Średnioroczne dobowe natężenie ruchu, średni dobowy ruch w roku
<i>SER</i>	Automatic Sound Event Recognition (Automatyczne rozpoznawanie zdarzeń dźwiękowych)
<i>SNR</i>	Signal-to-Noise Ratio (Stosunek sygnału do szumu)
<i>SVM</i>	Support Vector Machine (Metoda wektorów nośnych)

<i>TF</i>	True False (prawdziwie negatywna)
<i>TP</i>	True Positive (prawdziwie pozytywna)
<i>TPR</i>	True Positive Rate (czułość)
<i>TRISTAR</i>	TRójmiejski Inteligentny System Transportu AglomeRacyjnego
<i>VAD</i>	Voice Activity Detection (Detekcja mowy w sygnale)
<i>VSL</i>	Variable Speed Limit (Dynamiczne zmienianie prędkości dopuszczalnej)
<i>VIP</i>	Video Image Processor (Procesor przetwarzania sygnału wizyjnego)
<i>V2X</i>	Vehicle to Everything communication including vehicle to vehicle (V2V) and vehicle to infrastructure (V2I) (automatyczna łączność samochodu z infrastrukturą i innymi pojazdami)
<i>ZCR</i>	Zero Crossing Ratio (Gęstość przejść przez zero, Z_n)

Spis wielkości fizycznych

k	miara gęstości (ang. <i>density</i>) pojazdów przypadających na dany odcinek dróg (ruch pojazdów w potoku);
L	poziom dźwięku;
L_{Aeq}	równoważny poziom dźwięku korygowany krzywą A;
$Me(x)$	mediana - wartość środkowa dla cechy x ;
p_0	poziom ciśnienia odniesienia ($2 \cdot 10^{-5} Pa$);
p_A	chwilowa wartość poziomu ciśnienia akustycznego korygowanego krzywą A;
$p(t)$	ciśnienie dźwięku w funkcji czasu;
q	miara płynności potoku (ang. <i>flow</i>) (płynność pojazdów w ruchu);
r	współczynnik korelacji;
$R(x)$	obszar zmienności, rozstęp wartości będący różnicą wartości maksymalnej i minimalnej ze zbioru cechy x dla populacji;
s	odchylenie standardowe;
s^2	wariancja;
v	prędkość (ang. <i>speed</i> , u) - miara szybkości przemieszczenia się pojazdu/ów w ruchu;
v_{85}, v_{15}	kwantyle prędkości (85%, 15%);
V	natężenie ruchu (ang. <i>volume</i>);
\bar{x}	wartość średnia;

Spis treści

1	Wprowadzenie	19
1.1	Geneza i cel pracy	21
1.2	Zawartość rozprawy	22
2	Wprowadzenie do podstaw inżynierii ruchu drogowego	25
2.1	Zadania inżynierii ruchu	26
2.2	Zmienne opisujące warunki ruchu	28
2.3	Przegląd dostępnych rozwiązań ITS	32
2.3.1	Pętle indukcyjne	34
2.3.2	Detekcja optyczna	36
2.3.3	Detektory akustyczne	41
2.3.4	Systemy zarządzania ruchem drogowym	41
2.3.5	BALANCE	42
2.3.6	SCATS	43
2.3.7	Podsystemy Architektury systemów zarządzania ruchem	43
3	Akustyczna charakterystyka pojazdu	47
3.1	Hałas generowany przez poruszający się pojazd	48
3.1.1	Hałas toczenia	49
3.1.2	Hałas silnika i układu wydechowego	50
3.1.3	Wymagania prawne dotyczące ochrony przez hałasem drogowym	52
4	Wybrane metody uczenia maszynowego w akustyce	55
4.1	Ekstrakcja parametrów sygnału fonicznego	57
4.1.1	Wybrane parametry z dziedziny czasu i częstotliwości i ich charakterystyki statystyczne	61



4.1.2	Parametry związane z oceną hałasu źródła	66
4.1.3	Parametry jakości dźwięku (Sound Quality)	67
4.1.4	Graficzne reprezentacje sygnałów dźwiękowych	69
4.2	Wybrane metody uczenia maszynowego w przetwarzaniu dźwięku . .	71
4.2.1	Drzewa decyzyjne	75
4.2.2	k -najbliższych sąsiadów (k -NN)	75
4.2.3	Maszyna wektorów nośnych - SVM	76
4.2.4	Sieci neuronowe i głębokie sieci neuronowe	77
4.3	Przetwarzanie wstępne i analiza danych	79
4.3.1	Normalizacja	80
4.3.2	Miary bliskości, zgodności, rozrzutu danych	82
4.4	Ocena skuteczności systemów automatycznej klasyfikacji	85
4.4.1	Wskaźniki oceny skuteczności	85
5	Automatyczna klasyfikacja ruchu drogowego	87
5.1	Wymagania techniczne i założenia pracy systemu	88
5.2	Dźwiękowa baza danych drogowych	89
5.2.1	Akwizycja danych	89
5.2.2	Przetwarzania danych wejściowych	90
5.3	Realizacja algorytmów akustycznego monitoringu drogowego	92
5.4	Detekcja zdarzeń	93
5.4.1	Adaptacja progu detekcji	95
5.4.2	Zliczanie pojazdów	96
5.4.3	Detekcja typu pojazdu	101
5.4.4	Detekcja stanu nawierzchni	109
5.5	Podsumowanie działania akustycznego klasyfikatora ruchu drogowego	114
6	Podsumowanie i wnioski	115
6.1	Krytyczna ocena pracy	116
6.1.1	Proponowane zastosowania	118
6.2	Dalszy rozwój projektu	118
A	Parametry drogowe - podsumowanie	133

B Parametry użyte do klasyfikacji	135
C Wyniki klasyfikacji typu pojazdu	137
D Publikacje autorki	141
D.1 Dorobek Naukowy	141
D.2 Inne publikacje konferencyjne, monografie i książki związane z tematyką rozprawy	142
D.3 Patenty, granty i działalność wspierająca naukę	143

Rozdział 1

Wprowadzenie

Ważnym elementem środowiska, w którym żyje człowiek jest dźwięk. Dźwięk dostarcza człowiekowi wiele istotnych informacji dotyczących otoczenia, w którym się znajduje. Pełni rolę komunikacji, ekspresji, kontroli, wyraża treści za pomocą mowy. Pozwala wykryć zagrożenie zanim znajdzie się w zasięgu wzroku. Zrozumiała jest więc próba przeniesienia umiejętności słuchania i analizowania na urządzenia komputerowe. Pojęcia: „słyszenie maszynowe” (ang. Computer audition (CA); *Computer/machine listening*, *Machine Hearing* (MH)) czy „analiza sceny dźwiękowej” (*Auditory Scene Analysis* (ACA); *Computational Auditory Scene Analysis* (CASA)) pojawiły się w latach 90. ubiegłego stulecia [19], ale dopiero od niedawna – ze względu na rozwój metod, algorytmów i technologii informatycznych – praktyczne rozwiązania i systemy stały się możliwe i perspektywiczne [38, 134].

W grupie „Słyszenia maszynowego” można wyróżnić kilka podgrup akustycznych systemów analizy środowiska. Analiza dźwięku opracowywana jest na potrzeby między innymi autonomicznych robotów, urządzeń mobilnych [16, 59], wspomagając osoby niepełnosprawne (np. analiza sceny dźwiękowej w przypadku osób niewidomych lub niedowidzących, wspomaganie osób niedosłyszących, itd.) oraz ze względów bezpieczeństwa publicznego (np. systemy detekcji wystrzałów, eksplozji i innych dźwięków w pomieszczeniach publicznych i otoczeniu) [24]. Akustyczne systemy CASA znajdują zastosowanie również przy monitoringu rurociągów [132], których zabezpieczenie ma wymiar zarówno ekonomiczny, jak i w zakresie bezpieczeństwa. Osobny, ale i bardzo istotny obszar zastosowania słyszenia maszynowego obejmuje automatyczne rozpoznawanie muzyki w sieciowych technologiach muzycznych (np. w muzycznych systemach społecznościowych) [75, 126].

W rozprawie przedstawiono zagadnienia słyszenia maszynowego w odniesieniu do automatycznego wyznaczania natężenia ruchu, określania struktury ruchu, jak i stanu nawierzchni za pomocą pasywnej, akustycznej analizy otoczenia drogi. W badaniach uwzględniono zarówno zmiany krótkookresowe (dziennie, tygodniowe zmiany natężenia ruchu), jak i długookresowe (zmiany natężenia ruchu w ciągu roku), przy czym prowadzone analizy obejmują takie elementy ruchu, jak stan nawierzchni dróg, warunki pogodowe, zmiany doboru tras, przyzwyczajenia kierowców, itd.. Badania prowadzone w tym obszarze zostały obecnie wymuszone wieloma czynnikami. Wśród nich można wskazać z jednej strony rozwój technologii komputerowych, komunikacji bezprzewodowej, powstanie pojazdów autonomicznych, z drugiej zaś dbałość o środowisko (przeciwdziałanie hałasowi, zanieczyszczeniom powietrza, racjonalizacja transportu, itd.). Niezwiązane na pozór ze sobą elementy składają się na ekosystem zarządzania transportem.

Źródła hałasu w zurbanizowanym środowisku powodują zanieczyszczenie dźwiękami, ale mogą również wywoływać negatywne skutki odczuwane przez ludzi. W zależności od rodzaju źródła, jego intensywności i częstotliwości, ocena wpływu źródeł hałasu może być ilościowa i jakościowa. Przepisy dyrektywy UE [135] odnoszą się do oceny i zarządzania hałasem w środowisku spowodowanym ruchem, przemysłem i rekreacją na świeżym powietrzu. Z definicji hałas w otoczeniu jest niepożądanym lub szkodliwym dźwiękiem, najczęściej spowodowanym działalnością człowieka, w tym hałasem ulicznym. Hałas związany z ruchem drogowym należy do najbardziej uciążliwych i przeważających źródeł hałasu w miastach [107, 137]. Szkodliwe działanie hałasu odbija się zarówno na stanie psychicznym, jak i fizycznym mieszkańców, prowadząc nawet do ciężkiego uszczerbku na zdrowiu [90, 93].

Regularne opracowywanie map hałasu pozwala na wyznaczenie miejsc szczególnie narażonych na hałas drogowy i szybkie podjęcie środków naprawczych. Zgodnie z art. 7 dyrektywy [135], wymagania dotyczące przygotowania strategicznych map hałasu zostały określone w ramach oceny i zarządzania hałasem. Obserwacja rozplywu pojazdów na mapie obszaru umożliwia łatwiejsze zarządzanie przepływnością tras w kontekście generowanego hałasu. Gęsta zabudowa większości centrów starych miast jest najsilniej narażona na znaczne poziomy hałas. Dwupiętrowe i wyższe budynki w bezpośrednim sąsiedztwie dróg powodują występowanie zjawisk akustycznych jak w specyficznym kanale lub kanionie. Wzmaga to zjawisko wzmocnienia się hałasu w tego typu konfiguracji ulic. Na drogach zamiejskich, w których często jedynym źródłem hałasu jest hałas drogowy, natężenie ruchu i jego struktura bezpośrednio przekładają się na poziom generowanego hałasu. Umożliwia to tym samym jednoczesny pomiar natężenia ruchu i poziomu hałasu. Zastosowanie techniki inżynierii odwrotnej jest stosunkowo łatwym i szybkim zabiegiem pozwalającym na uzyskanie miarodajnych i precyzyjnych danych o natężeniu ruchu.

1.1 Geneza i cel pracy

Tematem prowadzonych badań było opracowanie ekonomicznego i skalowalnego rozwiązania wspomagającego zarządzanie ruchem drogowym na drogach szybkiego ruchu. Potrzeba ta wynika głównie ze względu na znaczne, wręcz rewolucyjne w ostatnich latach, przyspieszenie technologiczne w branży motoryzacyjnej i transportowej, czego wynikiem jest rozwój systemów komunikacji „pojazd-infrastruktura” (V2X, *Vehicle to everything*) w celu dostarczania informacji o zjawiskach związanych z ruchem drogowym. Zwiększające się natężenie ruchu, jak i pojazdy autonomiczne wymuszają zmiany w dotychczasowych systemach zarządzania ruchem (ITS, *Intelligent Transport Systems*).

Tematyka automatycznego uzyskiwania informacji o natężeniu ruchu jest rozwijana intensywnie w różnych aspektach w wielu ośrodkach na świecie [118, 121, 130], ale zwykle są to podejścia, w których bada się jeden wybrany aspekt inteligentnego zarządzania transportem. Ponadto, szeroka gama technologii akwizycji informacji i narzędzi przetwarzania sprawia, że wyniki prowadzonych badań są trudne do zastosowania w praktycznych zintegrowanych systemach zarządzania transportem.

Celem prowadzonych przez autorkę badań jest podejście hybrydowe, tj. stworzenie kaskadowego detektora łączącego wybrane technologie pozyskiwania informacji i wspomagany uczeniem maszynowym, aby zapewnić pomiar natężenia ruchu bez względu na warunki zewnętrzne panujące na drodze.

W rozprawie sformułowano następujące tezy pracy:

1. Możliwe jest określanie struktury liczbowo-rodzajowej potoku ruchu drogowego na podstawie analizy czasowo-częstotliwościowej hałasu emitowanego przez pojazdy, wspomaganej uczeniem maszynowym
2. Możliwe są detekcja i klasyfikacja stopnia suchości nawierzchni na podstawie wyników analizy akustycznej hałasu drogowego.


W celu udowodnienia tez rozprawy zarejestrowano i przeanalizowano nagrania ruchu drogowego. Posługując się deskryptorami czasowymi, częstotliwościowymi i czasowo-częstotliwościowymi, opracowano wektor cech opisujących poszczególne typy pojazdów. Zbadano charakter dźwięku generowanego przez poruszający się pojazd w różnych etapach zdarzenia (hamowanie pojazdu, jazda, itd.). Badania te przeprowadzono w różnych warunkach pogodowych, tj. przy suchej i mokrej nawierzchni drogi. W klasyfikacji rodzaju stanu nawierzchni wykorzystano algorytmy uczące się, które z bardzo dobrą dokładnością pozwalają ustalić czy jezdnia jest sucha czy mokra.

Celem cząstkowym było powiązanie klasy drogi ze średnio-dobowymi natężeniami ruchu, fluktuacjami w zależności od pory dnia i tygodnia oraz od średnich prędkości pojazdów. Stosując metody inżynierii odwrotnej i sieć sensorów akustycznych, możliwe jest zbadanie zachowania kierowców w miastach, przyzwyczajen oraz

obciążenia głównych sieci drogowych, jak i alternatywnych tras dobieranych przez kierowców. W rozprawie pokazano przykłady analiz, które pozwalają na opisanie rodzaju drogi i pośrednio – charakteru jej otoczenia na podstawie rozkładów poziomu hałasu.

1.2 Zawartość rozprawy

Struktura rozprawy przedstawia się w sposób następujący (rys 1.1). Rozdział drugi pracy zawiera przegląd dostępnych metod dynamicznego zarządzania ruchem drogowym. Przybliżono szeroko stosowane rozwiązania służące kontroli ruchu, oprogramowanie i specjalistyczne systemy automatycznego doboru systemów sygnalizacji świetlnej i przyznawania pierwszeństwa w ruchu (tzw. priorytetyzacja) pojazdów komunikacji zbiorowej.




Rysunek 1.1: Schematyczne ujęcie tematyki i struktury pracy, z opisem zawartości poszczególnych rozdziałów

Rozdział drugi przybliży podstawowe zagadnienia inżynierii ruchu drogowego. Skupiono się na przedstawieniu zmiennych mających znaczący wpływ na średnie

prędkości na drogach. Przedstawiono proces wyznaczania poszczególnych parametrów oraz ich dokładny wpływ na warunki panujące na drodze. Omówiono wybrane grupy urządzeń stosowanych współcześnie na drogach na przykładzie wybranych lokalizacji w województwie pomorskim, ze szczególnym uwzględnieniem urządzeń w dyspozycji GDDKiA oraz Gdańskiego Zarządu Dróg i Zieleni ze względu na współpracę z tą instytucją i udostępnione przez nią dane dotyczące charakterystyk dróg. Przedstawiono zalety i wady poszczególnych rozwiązań oraz ich typowe obszary stosowalności.

Rozdział trzeci skupia się na metodach przetwarzania dźwięku w systemach uczenia maszynowego (*ang. Machine Learning*), określanych niekiedy mianem algorytmów słyszenia maszynowego (*ang. Machine Hearing, Lyon 1982, [82]*), zwłaszcza w kontekście analizy sceny dźwiękowej. W pierwszej części rozdziału przedstawiono podstawowe zasady działania słuchu ludzkiego w odniesieniu do cyfrowej postaci rejestrowanego i przetwarzanego przez urządzenia analogowo-cyfrowe dźwięku. Następnie przedstawiono wybrane, podstawowe miary dźwięku, skupiając się na parametrach wykorzystanych przy realizacji części eksperymentalnej rozprawy. Scharakteryzowano parametry z dziedziny czasu, częstotliwości, czasowo-częstotliwościowe oraz ich miary statystyczne. W dalszej części rozdziału przedstawiono wybrane metody uczenia maszynowego, zestawiając je z istniejącymi projektami i badaniami nad systemami automatycznej detekcji i analizy dźwięku. Schemat postępowanie przybliżono na rys. 1.2.



Rysunek 1.2: Algorytmiczny schemat działania typowych systemów ML

Kolejne rozdziały dotyczą projektowanego klasyfikatora, wymagań stawianych urządzeniom telematki drogowej i metodom realizacji tych zadań. Przedstawiono uzyskane wyniki wraz z analizą istotności statystycznej.

Ostatni rozdział zawiera wnioski wynikające z opracowanych metod oraz podsumowanie uzyskanych wyników, które pozwoliły na udowodnienie postawionych w rozprawie tez. W rozdziale tym zawarto możliwe kierunki rozwoju prowadzonych prac oraz uwypuklono elementy rozprawy, mające charakter nowych rozwiązań. W Dodatkach przedstawiono szczegółowe wyniki klasyfikacji, schematy działania algorytmów, fragmenty kodów źródłowych oraz dorobek naukowy autorki rozprawy.

Rozdział 2

Wprowadzenie do podstaw inżynierii ruchu drogowego

Pojęcie inteligentnych systemów transportowych - ITS (ang. *Intelligent Transportation Systems*) utożsamia się z integracją systemów informatycznych (przetwarzanie informacji, komunikacja bezprzewodowa) i transportowych, które świadczą usługi z zakresu zarządzania ruchem, zapewniając równocześnie powszechny dostęp do informacji drogowych. Ich celem jest poprawa bezpieczeństwa, wydajności i wygody ogólnej sieci transportu kołowego [107]. Głównym zadaniem Inteligentnych Systemów Transportowych jest maksymalizacja efektywności wykorzystania i pojemności sieci komunikacyjnej. Spowodowane jest to między innymi ciągłym wzrostem liczby pojazdów przy ograniczonych możliwościach rozbudowy dróg [45]. W ramach ITS powstają lokalne lub globalne centra zarządzania transportem (TMC, Transportation Management Center), w których zbierane są dane dotyczące transportu, operacji i kontroli integrowane i dystrybuowane - w celu zarządzania siecią transportową (uwzględnia się w tym incydenty i katastrofy) i generowania informacji dla użytkowników transportu.

W niniejszym rozdziale omówione zostaną podstawowe zagadnienia z dziedziny inżynierii ruchu drogowego dotyczące zarządzania ruchem. Wyjaśniono podstawowe terminy związane z systemami transportowymi, metodami pomiarów natężenia ruchu i poprawy wydajności sieci drogowej.

Przedstawiono również technologie wykorzystywane w aktualnie dostępnych urządzeniach telematycznej drogowej. Wyjaśniono różnice między systemami sterowania a urządzeniami zbierającymi statystyki drogowe. W końcowej części rozdziału omówiono wymagania stawiane systemom zarządzania ruchem.

2.1 Zadania inżynierii ruchu

Według analiz Głównego Urzędu Statystycznego (GUS) liczba pojazdów osobowych w Polsce wynosi ponad 21,5 mln¹. Budowanie nowych dróg ograniczone jest zarówno uwarunkowaniami ekonomicznymi, przestrzennymi oraz urbanistycznymi. Wybudowane dawniej centra miast znajdowały się przy głównych szlakach komunikacyjnych, stąd też w wielu przypadkach główna droga biegnie przez centrum miasta w gęstej zabudowie mieszkalnej. Obecnie próbuje się zaradzić temu problemowi, budując drogi obwodowe, odciążające centra miast szczególnie od ruchu tranzytowego. Dodatkowo wiele miast staje się przyjazne pieszym, rowerzystom oraz uczestnikom komunikacji zbiorowej poprzez budowanie przejść dla pieszych z drogową sygnalizacją świetlną i dźwiękową, ograniczanie pasów ruchu w mieście, wydzielanie specjalnych pasów dla komunikacji miejskiej (buspas) i ścieżek rowerowych oraz ograniczanie prędkości w mieście, wspierając tym samym publiczny transport zbiorowy [107, 137] oraz ruch rowerowy.

Niektóre kraje europejskie prowadzą politykę "Car-free city", polegającą na stopniowej eliminacji ruchu pojazdów silnikowych z centrów miast. Doskonałym tego przykładem jest Madryt, w którym wprowadzono strefy 20 km/h i drogi jednokierunkowe, a część ulic dopuszcza wyłącznie ruch transportu zbiorowego, rowerowego i taksówek [71]. Innym europejskim przykładem jest Oslo planujące zminimalizować ruch pojazdów w mieście o 20% przed końcem 2019 roku [70]. Obecnie obserwuje się też wprowadzanie zakazu wjazdu pojazdów z napędem benzynowym, hybrydowym czy silnikami diesla do centrów miast europejskich i tworzenie tzw. ekostref (*ang. Eco Zones, Gree Zones*) [18, 29, 37, 136].

Do pozostałych, powiązanych ze sobą zadań ITS można zaliczyć [34]:

- redukcję czasu przejazdu,
- zmniejszenie opóźnień,
- poprawę płynności jazdy,
- poprawę bezpieczeństwa,
- redukcję kosztów transportu, utrzymania infrastruktury,
- redukcję zanieczyszczeń powietrza.

¹dane dotyczące 2016 roku [36]

Architektura typowego systemu ITS stanowi zespół narzędzi elektronicznego nadzoru, analizy ruchu oraz kontroli. Skuteczność systemu jest zaś silnie związana z formą i czasem aktualizacji danych o ruchu pojazdów. W poniższych podrozdziałach przedstawione zostaną wybrane, popularne urządzenia nadzoru ruchu drogowego. Przybliżone zostaną zasady ich działania oraz typowe scenariusze użycia. Obok wcześniej wymienionych elementów systemów ITS (np. centra zarządzania) można wymienić technologie komunikacji i kontroli pojazdów (ang. *Vehicle Control Technologies*), sterowanie sygnalizacją drogową (ang. *Traffic Signal Control*), obejmujące zintegrowane systemy autostrad i nawierzchni ulicznych w celu poprawy przepływu ruchu, bezpieczeństwo pojazdów i niezmotoryzowanych podróżnych, zapewnienie priorytetowych usług dla transportu publicznego lub pojazdów uprzywilejowanych, jak również zarządzanie ekosystemem (ang. *Incident Management*).

Dynamiczne zarządzanie ruchem wymaga uzyskiwania danych w czasie rzeczywistym. Pojęcie czasu rzeczywistego w kontekście systemów ITS może mieć różne znaczenie w zależności od istotności danych. Przyjmuje się, że aktualizacja danych dotyczących płynności ruchu powinna wynosić 10 minut (GDDKiA) lub 15 minut w amerykańskim modelu HCM (ang. *Highway Capability Model*)[11]. Na drogach szybkiego ruchu dochodzi do mniejszej liczby wypadków niż na drogach miejskich, jednak ze względu na dopuszczalne prędkości - skutki tych wypadków są znacznie poważniejsze. Moduły umożliwiające detekcję zdarzeń drogowych pełnią znaczącą rolę na długich odcinkach międzywęzłowych i drogach szybkiego ruchu. Komunikaty dotyczące obecności pojazdów uprzywilejowanych czy zdarzeń komunikacyjnych powinny być jak najszybciej przekazywane do zarządcy w celu uruchomienia odpowiedniego procesu. Dla przykładu średni czas transportu pacjenta do szpitala w mieście wynosi ok. 8-13 minut (poza miastem jest odpowiednio dłuższy), przy czym czas dojazdu do rannego w przypadku zatrzymania krążeniowo-oddechowego jest niezwykle kluczowy, bowiem już po 5 minutach dochodzi do trwałych uszkodzeń tkanki nerwowej [62]. Inna grupa informacji wymagająca wysokich rygorów czasowych dotyczy obecnie opracowywanych pojazdów połączonych (ang. *connected, cooperative vehicles*) czy też pojazdów autonomicznych, które wymagają minimalnych opóźnień w transmisji danych. Protokoły komunikacji V2X (ang. *Vehicle to Everything*) są obecnie w procesie standaryzacji i nie zostały jeszcze ustalone dokładne wymagania dotyczące sprzętowo-programowej obsługi i kontroli błędów, itp. Istnieje kilka pilotażowych programów testowych wspieranych przez producentów samochodów, np. Audi, Toyota, Ford, Volkswagen [42, 48, 94]. Na tym etapie zatwierdzeniu uległ jedynie standard wiadomości wymienianych w obrębie sieci V2X [117].

Dane mniej krytyczne z punktu widzenia bezpieczeństwa mogą napływać z niewielkimi opóźnieniami. Część danych jest zbierana w urządzeniach i przekazywana dalej w określonych przedziałach czasu w postaci zagregowanej lub wstępnie przetworzonej. Dane pobierane z klasycznych czujników niosą w sobie ograniczone zasoby informacyjne. W celu podejmowania adekwatnych decyzji zarządzający powinien mieć także możliwość weryfikacji napływających danych i podglądu sytuacji. Dlatego coraz częściej wprowadza się systemy wizyjne w monitorowaniu ruchu drogowego.

Pozwalają one na monitorowanie ruchu na bieżąco oraz dokumentowanie zdarzeń i podjętych działań.

W niniejszym rozdziale w pierwszej kolejności przedstawione zostaną podstawowe miary oceny ruchu drogowego oraz ich wpływ na zarządzanie natężeniem ruchu i prędkościami w ruchu [10, 34, 54, 119].

2.2 Zmienne opisujące warunki ruchu

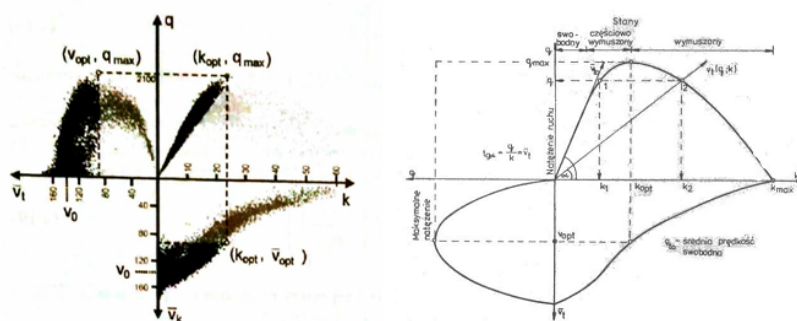
W obszarze IRD (inżynieria ruchu drogowego) można spotkać się z kilkoma terminami dotyczącymi warunków ruchowych poruszania się pojazdów[34]. Wyróżnia się stałe wartości określane mianem warunków drogowych (zmienne statyczne). Dotyczą one stałych parametrów drogi, jak jej geometria, przeszkody na drodze i w jej obrębie. Drugą grupę stanowią parametry dynamiczne, określane mianem warunków ruchu. Wpływają one na zachowania kierowcy (pośrednio i na dynamikę pojazdu), co przekłada się na płynność ruchu. Do czynników tych należy przypisać warunki pogodowe, struktura rodzajowa ruchu, oświetlenie i znajomość drogi przez kierowcę. Sprawny system zarządzania ruchem drogowym powinien uwzględniać oba typy zmiennych. W tabeli 2.1 przedstawiono pogrupowane środki prawne, psychologiczne i fizyczne decydujące o prędkościach na drodze.

Tabela 2.1: Prawne, psychologiczne i fizyczne czynniki decydujące o prędkościach osiągniętych na drogach [34]

Środki prawne	Środki psychologiczne	Środki fizyczne
<ul style="list-style-type: none"> • administracyjne limity prędkości • znaki ograniczające prędkość 	<ul style="list-style-type: none"> • optyczne zewężanie przekroju poprzecznego ulicy • wyświetlacze prędkości pojazdu 	<ul style="list-style-type: none"> • nadanie ulicy dużej krzywizny • zewężanie szerokości jezdni • progi zwalniające

Najpopularniejsze, istniejące modele wyznaczania przepustowości dróg obejmują m.in. wymieniony już wcześniej system HCM oraz niemiecki HBS-2001. W Polsce obowiązuje dodatkowo kilka instrukcji, między innymi z 1991 roku (dotycząca dróg zamiejskich) oraz dokumenty z 1995 roku - dotyczące dróg klasy 1 i 2.

Badania empiryczne przepustowości dróg pokazują zależność między natężeniem ruchu, prędkością i gęstością ruchu [15, 34]: Badania te wykazały, iż warunki drogowe charakteryzują się dużą niestabilnością w przypadku granicznych wartości przepustowości drogi. Spowodowane jest to dużym wpływem czynnika ludzkiego. Opisywane pomiary przedstawiono na rysunku 2.1. Znajomość maksymalnej przepustowości drogi przez system zarządzania drogami może pozwolić na podjęcie decyzji o wskazaniu możliwych dróg objazdu zanim nastąpi nasycenie danego odcinka. Należy zauważyć, że za komfortowe warunki jazdy dla kierowcy uznaje się sytuację,



Rysunek 2.1: Model empiryczny (po lewej) i model obliczeniowy równania ruchu [34]

w których kierujący może dowolnie dobrać prędkość jazdy i będzie miał możliwość wyprzedzenia pojazdu poruszającego się wolniej.

Aktualnie obowiązujące algorytmy wyznaczania swobody ruchu wymagają znajomości kilku parametrów ruchu. Są to geometryczne parametry analizowanego obszaru, typowa prędkość w ruchu swobodnym czy natężenie ruchu w formie pojazdów na minutę/godzinę. Na potrzeby niniejszych badań pominięto wpływ uwarunkowań geometrycznych na prędkość rzeczywistą pojazdu. Temat ten został jednak dokładnie przeanalizowany w źródłach literatury [11, 34, 73].

Podstawowy interwał pomiarów natężenia ruchu wynosi jedną godzinę. Dla celów specjalnych stosuje się interwały 5 i 15 minut, przykładowo przy wyznaczaniu przepustowości drogi oraz dynamicznego zarządzania sygnalizacją świetlną (2.3.4).

Prędkość pojazdu stanowi jedną z najważniejszych cech eksploatacyjnych drogi. Jej wartość jest silnie uwarunkowana bezpieczeństwem ruchu kołowego, a ograniczają ją głównie właściwości dynamiczne pojazdu i warunki pogodowe. Do pozostałych uwarunkowań można zaliczyć stan nawierzchni (w kontekście technicznego stanu dróg, warunków atmosferycznych oraz obecności zanieczyszczeń na drodze) oraz struktury rodzajowej ruchu (stosunek pojazdów ciężkich do lekkich). W inżynierii ruchu spotkać się można z kilkoma definicjami prędkości, w zależności czy dotyczy to terminologii technicznej czy pomiarowej. W obu przypadkach definicje i metody wyznaczania mogą się różnić. Warto jednak zaznaczyć, że nie zawsze prędkość dopuszczalna prawnie określa maksymalną wartość prędkości możliwą do osiągnięcia na danym odcinku drogi. Techniczne możliwości poszczególnych odcinków drogi decydują o prędkości dopuszczalnej dla całego odcinka. Dla przykładu: w pobliżu Bielska-Białej ostry zakręt, wynoszący więcej niż 90° , wymusił zmianę klasy drogi na fragmencie dotyczącym zakrętu (rys. 2.2).

Jak wspomniano wcześniej, w IRD istnieje kilka wariantów opisujących prędkość. Obok wcześniej wymienionych wielkość ta może być definiowana z uwzględnieniem uwarunkowań prawno-projektowych, jak np. zarządzanie prędkościami i ruchem drogowym. Na potrzeby niniejszej rozprawy doktorskiej skupiono się na określaniu prędkości stosowanych przy badaniu warunków ruchu.

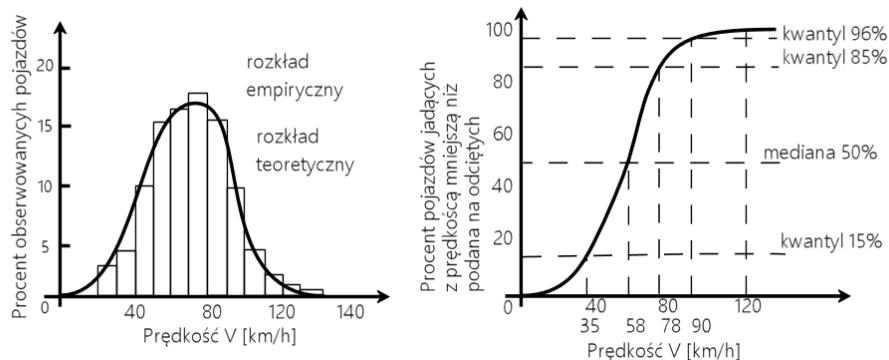


Rysunek 2.2: Wpływ warunków geometrycznych drogi na klasę drogi i dopuszczalne na niej prędkości (źródło: Google Maps)

Prędkość chwilowa

Prędkość chwilowa, oznaczana jako v_t , jest prędkością pojazdu w chwili pomiaru t w konkretnym przekroju drogi – punkcie, stąd też określana jest również jako prędkość punktowa. Pomiary wykonywać można na dwa sposoby, pierwszy z nich dotyczy pomiaru czasu potrzebnego na pokonanie odcinka testowego. W zależności od długości odcinka pomiarowego wykorzystuje się różne metody pomiaru. Dla odcinków między 30-100 m czas przebywania w obszarze pomiarowym może być wyznaczany za pomocą stopera, zaś dla krótszych odcinków wymagane jest zastosowanie dokładniejszej aparatury (przykładowo pomiar radarowy, optyczny, więcej w rozdziale 2.3). Drugi typ pomiaru - obciążony mniejszym błędem uśrednienia wartości - polega na pomiarze bezpośrednim miernikiem radarowym lub poprzez bezpośredni odczyt z licznika w pojeździe czy też danych GPS. Rozkład prędkości przedstawiany może być za pomocą histogramów, funkcji gęstości prawdopodobieństwa i dystrybuanty rozkładu (rys. 2.3). Określenie stopnia rozrzutu rejestrowanych prędkości ma duże znaczenie dla poziomu bezpieczeństwa ruchu drogowego. Im większy rozrzut prędkości, tym większe różnice między prędkościami pojazdów, co prowadzić może do częstych manewrów wyprzedzania [112].


Ze względu na rozpiętość prędkości rejestrowanych na drogach w praktyce badawczej przyjęło się stosować kwantyle z rozkładu - najczęściej 85% (lub rzadziej 96%). Innym istotnym pojęciem dotyczącym ruchu jest przepustowość drogi. Należy zauważyć, że nie projektuje się drogi na maksymalne możliwe obciążenie. W przypadku typowych dróg przyjęło się uwzględniać natężenie ruchu wynoszące 50 godzin (lub 100/150 godziny w przypadku dróg uwzględniających głównie ruch turystyczny).



Rysunek 2.3: Przykłady wykresu histogramu, gęstości prawdopodobieństwa i dystrybuanaty, rozkład normalny [66]

Zagęszczenie ruchu

Zagęszczenie ruchu wyznacza się na podstawie odległości między pojazdami w potoku ruchu. Przykładowo, jeżeli odległość między pojazdami wynosi 50 m, to gęstość $k = 1/d = 1/50m = 20poj./km$. Typowo przedstawiane jest to za pomocą wykresu prędkości do gęstości, przykłady diagramów potoków ruchu przedstawiono na rys. 2.4 [34].



Rysunek 2.4: Wykres zależności prędkości pojazdu w potoku ruchu od gęstości pokazujący granice przepustowości drogi

Struktura rodzajowa

Udział poszczególnych typów pojazdów pośrednio wpływa na rejestrowane prędkości chwilowe. W literaturze można spotkać kilka metod klasyfikacji pojazdów. Amerykański system FHWA (*Federal Highway Administration*) wydziela 13 różnych typów pojazdów. W Polsce obowiązuje podział na 16 rodzajów pojazdów (15+1), z czego każdy z rodzajów posiada wydzielone podrodzaje z podziałem na przeznaczenie pojazdu (Klasyfikacja pojazdów wg. ITS).

Część z tych systemów stosowane jest jedynie w statystykach opartych na bazach rejestru pojazdów. Przykładowo, klasyfikacja pojazdów wg. Dziennika Ustaw przewiduje 19 rodzajów pojazdów (nie uwzględniając pojazdów specjalnych).

W kontekście dynamicznego zarządzania ruchem strukturę rodzajową przedstawia się na podstawie udziału procentowego takich klas pojazdów, jak:

1. Motocykle i rowery
2. Samochody osobowe
3. Samochody dostawcze
4. Samochody ciężarowe bez przyczep
5. Samochody ciężarowe z przyczepami
6. Autobusy.

Współcześnie nawet zaawansowane detektory pomiarowe ograniczają klasyfikację pojazdów do trzech typów (osobowe, dostawcze, autobusy lub motocykle) lub podział na dwie grupy pojazdów: lekkie (osobowe, motocykle, małe pojazdy dostawcze) i ciężkie (pojazdy ciężarowe, autobusy). W niedalekiej przyszłości przewiduje się, że klasyfikacja nie będzie stanowić problemu ze względu na wdrożenie systemów V2X. Informacje przekazywane przez pojazdy zawierają numery VIN, które mogą być łatwo zamienione na właściwą kategorię pojazdu.

2.3 Przegląd dostępnych rozwiązań ITS

Początki klasycznej inżynierii ruchu sięgają 1928 roku, kiedy Charles Adler Junior wprowadził do obiegu pierwszą sygnalizację świetlną, sterowaną dźwiękiem. Urządzenie było sterowane sygnałem rejestrowanym przez mikrofon (np. dźwięk klaksonu samochodowego). Pierwszy taki sensor zainstalowano w Baltimor [45, 142].

W tym samym okresie Henry A. Haugh opracował innego typu sensor wrażliwy na nacisk. Był to pierwszy inwazyjny detektor pojazdów zbudowany z metalowych blach instalowanych w nawierzchni. Najechanie na płyty powodowało ich zetknięcie się, co w efekcie generowało napięcie. W ten sposób następowało wykrycie obecności

pojazdu. System ten cieszył się większą popularnością i był używany do lat 50. XX wieku. Wzorując się na tym urządzeniu, Adler opracował detektor innego typu, także akustyczny, polegający na detekcji dźwięku generowanego przez najechanie pojazdu na stalowe korytko. Jednak instalacje w nawierzchni drogi często ulegały uszkodzeniu, głównie z powodu zmiany warunków klimatycznych. Dalszy rozwój czujników i systemów ITS obejmował urządzenia instalowane przy drodze lub dobrze zabezpieczone w nawierzchni (pętle indukcyjne, magnetometry).

Automatyczne pomiary ruchu drogowego były prowadzone na szeroką skalę już w latach 80. ubiegłego wieku. Były to proste technologie, jak np. mechaniczne liczniki pojazdów i elektroniczne rejestratory przyciskowe. Nie tworzono wówczas jeszcze sieci zarządzających, a stacje pomiarowe były urządzeniami wykorzystywanymi głównie w celach statystycznych. Jednak bez zebrania informacji o warunkach pogodowych, skutkowały małą dokładnością odwzorowania rzeczywistych warunków dróg i możliwości kierowców.

W dalszych podrozdziałach omówione zostaną podstawowe sposoby badania parametrów ruchu drogowego. Przy czym termin detektor – oznacza ”urządzenie rejestrujące stan i zmiany poszczególnych parametrów ruchu” [34]. Wykorzystywane czujniki, stanowiące źródło sygnałów dla detektora, zależą od wybranej technologii.

Poniżej podano metody analizy ruchu umożliwiające detekcję i opis zdarzeń w ruchu drogowym:

- **akustyczna**,
- **optyczna**(obecność pojazdu lub zdarzenia obserwowana optycznie, np. poprzez kamery, kamery VIP (Video Image Procesor) lub kamery z oświetlaczem podczerwieni),
- **magnetometryczna** (wykorzystywane właściwości geomagnetyczne w magnetometrach),
- **indukcyjna** (wykorzystywane właściwości pola elektromagnetycznego w pętlach indukcyjnych),
- **wibroakustyka** (wibracje),
- **detekcja za pomocą sygnałów sondujących** (np. radary mikrofalowe, Doppler, podczerwień).

Każda z tych metod posiada pewne ograniczenia wynikające z warunków pomiarowych, jak i parametrów badanego obiektu. Poniżej zaprezentowane zostaną wybrane sensory z omówieniem zasad ich działania i ograniczeń [45]. Przytoczone charakterystyki tych urządzeń posłużyły do weryfikacji działania opracowywanego w rozprawie klasyfikatora ruchu.

Współczesne urządzenia do monitorowania liczby pojazdów oraz ich parametrów można podzielić na kilka kategorii. Jednym z możliwych podziałów jest rozdzielanie na urządzenia inwazyjne, czyli montowane w/na jezdni lub krawężnikach (*ang. in-roadway*). Są to wszelkiego rodzaju pętle indukcyjne, czujniki nacisku, magnetometry, itp. (*ang. inductive loop detectors, weigh-in-motion sensors, magnetometers, tape switches, microloops, pneumatic road tubes, piezoelectric cables*).

Drugą kategorią są urządzenia montowane na konstrukcjach nad jezdnią, (np. bramownice), na słupach lub budynkach wzdłuż jezdni (*ang. on-roadway*). Wyróżnia się kamery przetwarzające obraz wizyjny (VIP), radary mikrofalowe (MD), ultradźwiękowe (UD), pasywne detektory dźwiękowe (PAD, PADA) [45, 121, 130].

Innym podziałem jest rozróżnienie ze względu na sposób działania urządzenia. Podział ten uwarunkowany jest rodzajem urządzenia w zależności od tego czy wysyła dodatkowe sygnały pozwalające określić obecność i parametry pojazdu, czy jest to pasywne urządzenie, którego zadaniem jest analiza sygnałów emitowanych przez pojazd. Przyjęte podziały zaprezentowano w tabeli 2.2.


Tabela 2.2: Systematyka dostępnych urządzeń telematyki drogowej służących do detekcji pojazdów i ustalania parametrów ruchu [45]

Detektory pasywne	Detektory aktywne
Optyczne: <ul style="list-style-type: none"> • kamery VIP • pasywna podczerwień Akustyczne: <ul style="list-style-type: none"> • macierz sensorów • pojedyncze mikrofony Elektromagnetyczne	Optyczne: <ul style="list-style-type: none"> • laserowe • IR Mikrofalowe: <ul style="list-style-type: none"> • Doppler 24GHZ Magnetometry

W rozdziale 5.4.2 przedstawiono wyniki badań pomiaru natężenia ruchu z wykorzystaniem kilku różnych technologii detektorów nieinwazyjnych umieszczonych w pasie pobocza drogi. Poszczególne urządzenia monitorowały ten sam przekrój drogi, zapewniając równocześnie najwyższą możliwą skuteczność urządzenia. Wykorzystywano zarówno komercyjne produkty, jak i systemy opracowane przez autorkę. Badania przeprowadzono w pojedynczej lokalizacji dla różnych warunków atmosferycznych i oświetleniowych. Badania miały na celu stworzenie kaskadowego detektora łączącego wybrane technologie w celu zapewnienia jednakowego pomiaru natężenia ruchu bez względu na warunki zewnętrzne panujące na drodze, wspomagane uczeniem maszynowym.

2.3.1 Pętle indukcyjne


Najbardziej popularnym rozwiązaniem jest stosowanie pętli indukcyjnych (rozwiązanie "inwazyjne", montowane pod nawierzchnią drogi). Instalacja tego typu wykrywa pojazd i w zależności od jego profilu elektromagnetycznego klasyfikuje jako konkretny typ pojazdu. Prędkość pojazdu i natężenie wyznaczone jest na podstawie analizy zapisów z kilku par pętli. Jednak te powszechne i stosunkowo tanie rozwiązania posiadają liczne wady powodujące poszukiwanie innych sensorów do zarządzania ruchem. Do najczęściej występujących problemów można zaliczyć:



Rysunek 2.5: Widoczne cięcia po wprowadzeniu pętli indukcyjnych (para na każdy pas ruchu - (po lewej) wraz z wyprowadzeniem połączeń fiderem prowadzącym sygnały do detektora, urządzenia VIP wraz z oświetlaczem (po prawej)

- pęknięcia i przesunięcia nawierzchni,
- przerwanie mechaniczne pętli,
- niskiej jakości wypełnienie wgłębień po instalacji, jak i zastosowanie niskiej jakości elementów,
- przedostanie się wody do instalacji,
- przesłuchy między sąsiednimi pętlami,
- uszkodzenia mechaniczne wywołane przez ciężkie pojazdy stojące na światłach
- błędna kalibracja urządzeń,
- naprawy wymagające zamknięcia pasa lub całej jezdni.

W przypadku instalacji grupy czujników (jezdnie wielopasmowe) może dochodzić do przesłuchów między pętlami, powodując błędne zliczenia lub błędną klasyfikację. Ograniczenia i problemy spowodowały wzrost zainteresowania systemami instalowanymi na bramownicach nad jezdnią lub na słupach wzdłuż jezdni. Przykład instalacji pętli indukcyjnych oraz systemów instalowanych nad drogą (kamery) przedstawiono na rys. 2.5. Pętle indukcyjne zainstalowano między linią zatrzymania a przejściem dla pieszych (lewa strona rysunku), unikając tym samym sytuacji, kiedy pojazd przez dłuższy czas znajduje się na pętli indukcyjnej. Po prawej stronie rys. 2.5 widać komplementujące urządzenia VIP (obraz wizyjny) wraz z oświetlaczem. Zdjęcia wykonano na skrzyżowaniu w Gdańsku-Wrzeszczu na skrzyżowaniu ulic: Grunwaldzka-Do Studzienki.



Rysunek 2.6: Zjawisko przesłaniania większego pojazdu przez drugi powodujące błędy w pomiarach w zliczaniu pojazdów w systemach instalowanych przy drogach


2.3.2 Detekcja optyczna

Urządzenia instalowane nad jezdnią obarczone są większymi błędami pomiarowymi niż analiza z poziomu nawierzchni. Do najczęściej występujących problemów należy zaliczyć przesłanianie się obiektów (rys. 2.6). Kolejnym problemem jest detekcja pojazdów o nietypowych kształtach i materiałach, które mogą zakłócać działanie wiązki sondującej poprzez efekt rozpraszania.

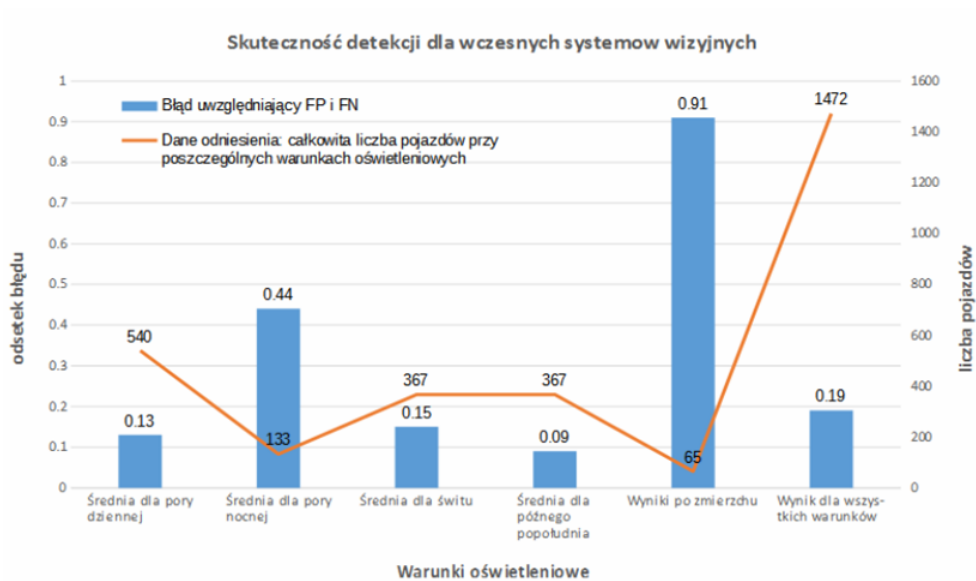
Urządzenia do detekcji optycznej pojazdu można podzielić na pasywne i aktywne. Pierwszą grupę stanowią głównie urządzenia wizyjne (ang. Video Image Processor) śledzące i klasyfikujące obiekty/zdarzenia w obrazie wizyjnym na podstawie algorytmów przetwarzania obrazu. Systemy VIP charakteryzują się dużą funkcjonalnością, jednak ich nieingerencyjny charakter powoduje również ograniczenia. Naprawa i instalacja urządzeń nie wymaga zamknięcia pasa czy też jezdni, jak w przypadku pętli indukcyjnych. Problemem jest dopasowywanie nastaw do zmiennych warunków oświetleniowych i dużo mniejsza skuteczność dla pory nocnej i warunków ograniczonej widoczności (np. mgła, intensywny deszcz). Ponadto, zanieczyszczenia osadzające się na obiektywach pogarszają stopniowo skuteczność systemów, wymaga to więc regularnej konserwacji. Na poniższych zdjęciach (rys. 2.7) przedstawiono problematyczne sytuacje związane z użytkowaniem kamer wizyjnych do analizy warunków drogowych.

Systemy VIP z lat 90. charakteryzowały się stosunkowo dużą podatnością na błędy w porze nocnej (rys. 2.8). Współczesne systemy stosują nowsze, efektywniejsze przetworniki uzyskujące lepszą rozdzielczość wizyjną. Wyposażane są również w systemy systemami doświetleń oraz dodatkowe zabezpieczenia przed opadami atmosferycznymi.


Drugą grupę sensorów optycznych stanowią urządzenia wykorzystujące technologię laserową. Technologia LiDARowa mierzy odległość od celu na podstawie sygnału odebranego po oświetleniu obiektu modulowaną wiązką laserową. Stosowanie różnych szerokości wiązek, odpowiedni dobór ich częstotliwości oraz wykonywanie pomiarów dalekiego zasięgu pozwalają na stosowanie urządzeń w systemach telema-



Rysunek 2.7: Różne sytuacje drogowe uchwycone przez kamery drogowe (źródło: dailymail.co.uk, oraz kamery GDDKiA)



Rysunek 2.8: Efektywność wczesnych systemów VIP, badania przeprowadzone w 1998 roku przez Kalifornijski Instytut Technologii w Pasadenie)




Rysunek 2.9: Podstawowe parametry i zasady konfiguracji urządzeń LiDARowych

tyki drogowej. Technika ta używana jest również przy skanowaniu 3D i pojazdach autonomicznych.

W trakcie prowadzonych badań terenowych wykorzystano urządzenie POLI-SCAN SPEED MOBILE. Zbadano różne ustawienia urządzenia i ich wpływ na skuteczność systemu. Uwzględniając zasadę działania techniki LiDARowej, nadajnik musi być skierowany w najbardziej odbijający element na pojeździe - tablicę rejestracyjną lub reflektory. Typowe ustawienie urządzenia zaprezentowano na rysunku 2.6. Przy ustawianiu systemu należy pamiętać o kilku stopniach swobody, wymagających optymalizacji ustawień:

- wysokość urządzenia względem nawierzchni drogi (środek elementu LiDARowego, wysokość h na rys 2.9)
- odległość od drogi,
- szerokość drogi, liczba pasów,
- kąt w płaszczyźnie horyzontalnej,
- kąt w płaszczyźnie wertykalnej,
- kąt generowanej wiązki;
- odległość od pojazdów - długość strefy detekcji i pomiaru (długość d na rys 2.9).

Inna metoda stosowania technik optycznych polega na skanowaniu pojazdów z góry (instalacje na bramownicach). Stosują one wielowiązkowe systemy laserowe o stałym sygnale. Wynik działania takiego systemu przedstawiono na rys. 2.10. Porównanie zalet i wad czujników optycznych przeprowadzono w tabelach 2.3 i 2.4.



Rysunek 2.10: Obrazowanie 3-D pojazdu z przyczepą (Zdjęcie z zasobów Schwartz Electro-Optics, now OSI Laserscan, Orlando, FL)

Tabela 2.3: Zalety i wady stosowania czujników optycznych [45]

Technologia:	Optyczne <i>infrared</i>
Zasada działania:	Aktualnie dostępne systemy w Europie działają w trybie aktywnym. Na podstawie odbitej energii pozyskuje się informację o typie pojazdu i jego parametrach.
Zalety: <ul style="list-style-type: none"> • Brak interferencji między urządzeniami pracującymi obok siebie (przy stałych wiązkach) 	Wady: <ul style="list-style-type: none"> • Skuteczność spada w gorszych warunkach atmosferycznych (mgła, śnieg) • Wymaga konserwacji soczewek nadajnika i odbiornika (może wymagać zamknięcia pasa ruchu) • W zależności od instalacji może zachodzić zjawisko okluzji
Montaż: Nieinwazyjny, spotykane systemy pracujące na wysokości od 0,5 m-21 m	Możliwości <ul style="list-style-type: none"> • natężenie, • prędkość, • długość pojazdu, • długość kolejki pojazdów • klasyfikacja 11 typów (rozdzielanie pojazdów z przyczepami od długich pojazdów)

Tabela 2.4: Zalety i wady stosowania czujników optycznych VIP [45]

Technologia:	Optyczne VIP
<p>Zasada działania:</p>	<p>Wizyjna analiza sytuacji na drogach, zazwyczaj operacje przetwarzania obrazu i wnioskowania wykonywane są wewnątrz urządzenia, przekazując do centrów danych jedynie informacje numeryczne (wyjątek stanowią kamery CCTV)</p>
<p>Zalety:</p> <ul style="list-style-type: none"> • Może monitorować różne pasy/punkty detekcji • Zastosowanie w różnych gałęziach transportu (pojazdy kołowe, szynowe, rowery, piesi) • Łatwa możliwość rozbudowy i poprawy funkcjonalności urządzenia, 	<p>Wady:</p> <ul style="list-style-type: none"> • Dla najlepszej wydajności należy stosować wysokie maszty(9-15m) • Instalacja i konserwacja niekiedy wymaga zamknięcia pasa jezdni lub jego części, • Wymaga regularnej konserwacji - czyszczenia obiektywów, • Dokładność systemu zależna od warunków pogodowych - mgła, śnieg, deszcz • Może dochodzić do zjawiska okluzji (szczególnie przy kamerach obok jezdni), • Silne wiatry lub przejazdy pojazdów ciężkich mogą powodować drżenie kamer i zakłócać w ten sposób odczyt, • Zwiększanie stref detekcji ograniczona jest możliwościami sprzętowymi (zazwyczaj nie rozbudowywanymi w obrębie pojedynczego urządzenia), • Analiza obrazu w centrum danych wymaga dużego pasma do transmisji strumieniowej.
<p>Montaż: Nieinwazyjny, wymaga wysokich masztów (9-15m), niższe dla niepełnej funkcjonalności systemu</p>	<p>Możliwości:</p> <ul style="list-style-type: none"> • natężenie, • prędkość (przy odpowiednim montażu i rozdzielczości obrazu), • długość pojazdu, • długość kolejki pojazdów • klasyfikacja 11 typów (rozdzielanie pojazdów z przyczepami od długich pojazdów) • rozpoznawanie tablic rejestracyjnych (ANPR).

2.3.3 Detektory akustyczne

Detektory akustyczne działają na zasadzie parametryzacji sygnału dźwiękowego otoczenia drogi oraz klasyfikacji zdarzeń, jakim jest przejazd pojazdu. Na podstawie analizy czasowej i częstotliwościowej rejestrowanego sygnału można określić prędkość, typ oraz kierunek jazdy pojazdu. Urządzenie działa na zasadzie obserwacji otoczenia, nie generując przy tym dodatkowych sygnałów sondujących mogących wpływać na prace innych urządzeń telematiki drogowej czy też czujników grupy *Vehicle Awarness*² w pojeździe. W przypadku dużych prędkości pojazdu, główne źródło dźwięku pochodzi od opon i ich kontaktu z podłożem. Przy niższych prędkościach bardziej dominujący staje się hałas generowany przez silnik.

Detektory akustyczne mogą być zbudowane z jednego mikrofonu lub z macierzy mikrofonów. Konstrukcja detektora decyduje o skuteczności urządzenia i jego funkcjonalności. Dla przykładu nie jest możliwe uzyskanie informacji o kierunku jazdy z wykorzystaniem jednego mikrofonu monofonicznego. Większą skuteczność daje zastosowanie sygnału stereofonicznego, bowiem analogicznie do zmysłu ludzkiego słuchu tego typu detektor jest w stanie zlokalizować źródło dźwięku. Typowo, detektor lokalizuje obiekty wzdłuż linii drogi z osią skierowaną na pasy jezdni. Skuteczność rozpoznawania tych systemów spada dla pojazdów poruszających się bardzo powoli (minimalne zmiany w poziomie hałasu) lub stojących, stąd też nie jest zalecane montowanie/stosowanie detektorów akustycznych w pobliżu skrzyżowań – bardziej zasadne jest ich montaż przy głównych drogach szybkiego ruchu.

Pasywne radary akustyczne znajdują zastosowanie również jako systemy wspomaganie osób niepełnosprawnych [27, 63, 79].

2.3.4 Systemy zarządzania ruchem drogowym


Omówione powyżej detektory wchodzi w skład systemów zarządzania ruchem. Sprawność i efektywność sieci drogowej uzależniona jest od całej architektury, w której skład wchodzi detektory, systemy zarządzania poszczególnymi blokami usług, jak i oprogramowanie decyzyjne.

W zależności od celu ruchu inne będą priorytety działania systemów. Na rys. 2.11 przedstawiono podział ruchu drogowego. W zależności od badanego obszaru i typu drogi można mówić o innej charakterystyce ruchu. W kolejnych rozdziałach przedstawiono metody modelowania ruchu z punktu widzenia systemów informatycznych. W zależności od obszaru działania omawiany będzie model makroskopowy i mikroskopowy [34, 72]:

- **Model makroskopowy** - macierz dopływów i odpływów ruchu mierzalnych na granicach sieci;

²Pojazdy grupy Self-Driving (autonomiczne) jak i obecne pojazdy wspomagane są przez szereg sensorów wspomagających jazdę (podczerwień, wideo, ultradźwiękowe [145])

- **Model mikroskopowy** - uwzględnia wpływ sygnalizacji świetlnej, czasu podróży i rozkład kolumny pojazdów w czasie w zależności od prędkości;



Rysunek 2.11: Terytorialny podział ruchu [66]

Europejska Ramowa Architektura IST (ang. *European ITS Framework Architecture*) określane jako Architektura FRAME lub po prostu FRAME stanowi opracowanie spójnej architektury systemów i usług ITS dla obszaru Europy [41]. Projekt ten powstał w ramach europejskiego programu KAREN (ang. *Keystone Architecture, Required for European Networks*) trwający od 1998 roku do 2000 [72].

Aktywne Zarządzanie Ruchem (ang. *Active Traffic Management*) jest narzędziem służącym do stabilizacji potoków ruchu, poprawie bezpieczeństwa poprzez dynamiczne zarządzanie i kontrolowanie ruchem, bazując na aktualnym stanie natężenia ruchu (system czasu rzeczywistego).

Całość architektury spinana jest oprogramowaniem przetwarzającym informacje pochodzące z dróg na potrzeby sterowania ruchem. W Polsce – do najbardziej znanych – należą systemy: BALANCE i SCARS [118, 146].

2.3.5 BALANCE

Adaptacyjne sterowanie sieciowe (ang. *Balancing Adaptive Network Control Method*) jest metodą zawierającą w sobie model makro i mikro. Na metodzie BALANCE opiera swoje działanie system TRISTAR. Twórcą modelu jest niemiecki koncern GEVAS, stąd wcześniejsze wdrożenia miały miejsce głównie na zachodzie Europy (Dusseldorf, Frakfurt, Salzburg, Regensburg) oraz w Belgradzie [72, 146]. System posiada dwupoziomową hierarchiczną architekturę. Lokalnie, zmiany w systemie wprowadzane są co 1 sekundę (mikroskopowy) - analiza sytuacji w obrębie skrzyżowania, udzielanie priorytetu transportowi zbiorowemu. Poziom taktyczny

(makroskopowy) działa w trybie średnioterminowym lub długoterminowym (5 - 15 minut). Decyduje o zakresie dostępnych trybów sygnalizacji dla skrzyżowań skupionych w obrębie grupy. Każde skrzyżowanie z w obrębie danej grupy wybiera jeden z predefiniowanych trybów według wskazań lokalnego detektora. System informacyjny stanowi zbiór modeli matematycznych, optymalizowanych za pomocą algorytmów genetycznych. Główną korzyścią/celem stosowania systemu BALANCE jest minimalizacja opóźnień (strat), dążąca do skrócenia czasu przejazdu. W ogólności zadaniem systemu jest skrócenie zajętości trasy. Jest to typowe dla ruchu miejscowego związanego z poruszaniem się do-z pracy/szkoły. Minimalizacja oczekiwania na zielone światło ma za zadanie minimalizować emisje CO_2 w miastach.

2.3.6 SCATS

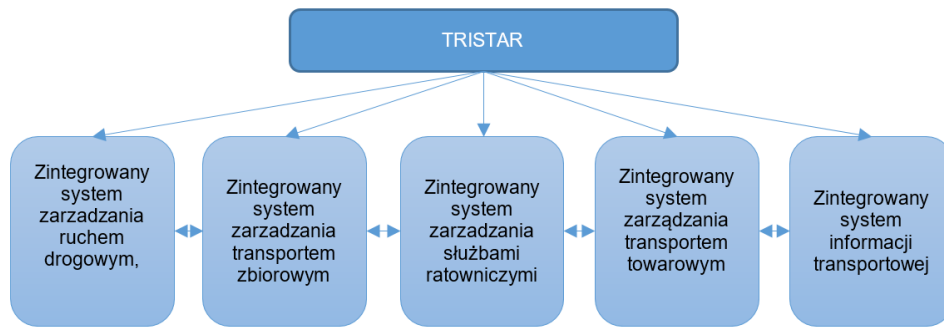
Sydney Coordinated Adaptive Traffic System System jest to australijski system tworzony od ponad 30 lat (aktualizacje udostępniane są co 9 miesięcy) [118]. Jego głównym zadaniem jest dostrajanie faz sygnalizacji świetlnej w czasie rzeczywistym. Źródła danych stanowią głównie pętle indukcyjne i detektory pieszych w formie przycisków instalowanych na przejściach dla pieszych. Obecnie, system zainstalowany jest w 40 różnych państwach.

Działanie systemu oparte jest na architekturze rozproszonej i działa na dwóch poziomach – lokalnym (LOCAL) dotyczącym kontroli w obrębie detektora i głównym (MASTER) umożliwiającym kontrolę nad całym zarządzanym terenem (ang. *area traffic control* – ATC lub *urban traffic control* - UTC). Detektory przetwarzają dane z czujników (LOCAL) i przekazują je do głównego systemu (MASTER). Możliwe jest stosowanie sterowników i systemów różnych producentów wewnątrz architektury; system działa w środowisku Windows. Komunikacja w obrębie systemu SCATS może przebiegać za pomocą sieci PAPL, ADSL, PSTN i 3G IP [118, 146].

Z punktu widzenia inżynierii ruchu system SCATS dopasowuje się do warunków ruchu na podstawie przepustowości, kierując się współczynnikiem nasycenia drogi niż aktualnym natężeniem ruchu. Dodatkowo większa waga przywiązywana jest do rzeczywistych odstępów między pojazdami a nie ogólnej liczby pojazdów przypadających na okres pomiarowy. System w czasie rzeczywistym (co 1 sekundę) reaguje na zmiany warunków atmosferycznych i zdarzenia drogowe. Wszystkie te właściwości umożliwiają szybką adaptację do warunków ruchu, wg producentów poprawia on wykorzystanie sieci drogowej o 20-40% [66]. Trzeci system - MOTION (ang. *Method for the Optimization of Traffic Signals in Online Controlled Networks*) - obejmuje trzy poziomy funkcjonowania: strategiczny - 5-15 min, taktyczny - aktualna długość cyklu (60-90 sekund) i operacyjny - co sekundę [72].

2.3.7 Podsystemy Architektury systemów zarządzania ruchem

Jedną z podgrup systemów ATM są systemy dynamicznego sterowania prędkościami (ang. *VSL* - *Variable Speed Limit*). Głównym zadaniem tych systemów jest



Rysunek 2.12: Konceptyjny schemat podsystemów zarządzania ruchem w systemie TRISTAR [55]

poprawa efektywności wykorzystania infrastruktury drogowej. Osiągnięte jest to poprzez synchronizację prędkości poruszających się pojazdów, stabilizując tym samym ruch na drodze.

W większości systemów tego typu dynamiczne zarządzanie prędkościami wykorzystuje informacje o liczbie pojazdów, natężeniu ruchu i średniej prędkości. Allaby (2006) na przykładzie londyńskiej drogi M25 przedstawił system minimalizowania występowania fali zaburzeniowej (ang. *shockwaves*) na podstawie natężenia ruchu. Osiągnięcie pewnych progów natężenia ruchu skutkowało dynamicznym ograniczeniem prędkości na drodze (VSL)[4]. Papageorgiou wraz ze współpracownikami (2008)[105] zaproponował podejście uwzględniające krzywe zajętości - potoku ruchu do wyznaczania punktów aktywacji zmiany zalecanej prędkości – w pracy tych autorów nie podano jednak zastosowanych algorytmów.

Z kolei Kuhne (1991)[67] zaproponował podejście uwzględniające aktualną gęstość natężenia ruchu, prędkość średnią w potoku i odchylenie standardowe prędkości, stosując dla tych wielkości trzy odrębne wartości progów. W Chinach do dynamicznego zarządzania prędkościami stosowano następujące parametry: natężenie ruchu, stan nawierzchni i warunki pogodowe. Poza podejściem progowym czy też wykorzystującym algorytmy decyzyjne, np. drzewo decyzyjne, w literaturze można znaleźć opracowania systemów wnioskujących na podstawie wyników maszyny wektorów nośnych (SVM) (Liang et al., 2005), rozmytych sieci neuronowych (Chenn, 2009) czy algorytmów genetycznych [25, 58]. Proponowane przedziały obserwacji wahają się zwykle od 1 minuty do 15 minut. System zarządzania ruchem zostanie omówiony dokładniej na przykładzie trójmiejskiego systemu TRISTAR (Trójmiejski Inteligentny System Transportu Aglomeracyjnego). Systemy zarządzania ruchem typowo składają się z kilku podsystemów, z których każdy zajmuje się inną gałęzią transportu. W przypadku systemu TRISTAR, można go koncepcyjnie podzielić na pięć podsystemów, które schematycznie przedstawiono na rysunku 2.12.

System zarządzania ruchem na trójmiejskich drogach został uruchomiony w 2015 roku [56, 57]. Głównym celem systemu było skrócenie czasu przejazdu o 20%, prace nad jego strukturą trwały od 2002 roku i opracowane zostały przez naukowców z Wydziału Inżynierii Lądowej Politechniki Gdańskiej. Elementy systemu TRISTAR

	Czas UTC	system	traffic_station_id	event_type	control_point_id	vehicle_class	vehicle_direction
1	2016-01-01 00:00:00.4600000	42	8	1	6	2	0
2	2016-01-01 00:00:15.3600000	42	8	1	5	3	0
3	2016-01-01 00:00:18.2700000	42	8	1	10	2	0
4	2016-01-01 00:00:18.3100000	42	8	1	5	2	0
5	2016-01-01 00:00:19.5000000	42	8	1	6	2	0

vehicle_speed	vehicle_length	time_on_control_point	distance_from_previous	id	T_ETLProcessId	event_d
48	33	7	42	3197880580	59644	2016-01
40	60	10	265	3197880581	59644	2016-01
53	34	6	324	3197880582	59644	2016-01
43	36	7	30	3197880583	59644	2016-01
44	49	8	16	3197880584	59644	2016-01

Rysunek 2.13: Ilustracja danych z detektorów indukcyjnych z systemu TRISTAR (dzięki uprzejmości ZDiZ Gdańsk)

obejmują:

- pętle indukcyjne,
- skanery Bluetooth i Wi-Fi (monitoring pojazdów na podstawie wykrytych indywidualnych adresów MAC). Zrealizowany w Gdyni przez firmę QUMAK program pilotażowy wykazał, iż co trzeci pojazd udostępnia swój adres MAC,
- kamery ANPR (ang. *Automatic Number Plate Recognition*), posiadające funkcję rozpoznawania tablic rejestracyjnych pojazdów,
- tablice zmiennej treści,
- drogowe stacje meteorologiczne,
- tablice informacji pasażerskiej,
- kamery obrotowe monitoringu miejskiego

Informacji o stanie dróg dostarczają pętle indukcyjne. Detektory rejestrują informacje o prędkościach pojazdów i strukturze rodzajowej pojazdów. Rejestrowanie każdego rekordu (pojazdu wykrytego przez pętle) pozwala na uzyskanie informacji statystycznych takich, jak średnia prędkość dla zadanego interwału czasowego czy odległości czasowe między poszczególnymi pojazdami. Ilustrację danych pozyskanych z detektorów przedstawiono na rys. 2.13, zaś w tabeli 2.3.7 przedstawiono opis wybranych parametrów z detektorów indukcyjnych w systemie TRISTAR).

W systemie zaimplementowano model DRIVRS, aktualizujący co 5 min informacje o natężeniu na poszczególnych skrzyżowaniach, dane te pochodzą z optycznych detektorów instalowanych nad pasami. W przypadku skrzyżowań, gdzie każdy z pasów wyposażony jest w detektory, dane zawierają informację o rozplywie poszczególnych potoków ruchu na różne obszary Trójmiasta. Bazą do obliczeń stanu dróg są dane archiwalne i bieżące - uzyskiwane z pomiarów.

Lp.	Nazwa	Funkcja i format
1	Czas.UTC	moment zarejestrowania zdarzenia yyy-mm-dd hh:mm:ss
3	traffic_station_id	lokalizacja punktu pomiarowego
5	control_point_id	wartość uzależniona od liczby czujników na skrzyżowaniu, liczona od 0
6	vehicle_class	0 - 5, gdzie: 0 - pojazdy niesklasyfikowane > 25 m, 1 - niesklasyfikowane o dł. 22-25 m 2 - osobowe 3 - dostawcze 4 - ciężarowe i autobusy 5 - jednoślady
8	vehicle_speed	prędkość pojazdu w km/h
9	vehicle_length	długość pojazdu podana w decymetrach i maksymalna wartość to 255
10	time_on_control_point	czas przebywania na punkcie pomiarowym
11	distance_from_previous	odległość pomiędzy pojazdami przejeżdżającymi przez punkt kontrolny

Rozdział 3


Akustyczna charakterystyka pojazdu

Akustyczna analiza ruchu drogowego pojawiła się na początku XIX wieku. W przypadku, gdy analiza strumienia ruchu przeprowadzana jest głównie na bazie analizy obrazu (VIP) i informacji z pętli indukcyjnych, parametry akustyczne mogą dostarczyć dodatkowych informacji dotyczących bezpieczeństwa i jakości ruchu. Najczęściej dotyczy to detekcji pojazdów uprzywilejowanych [6, 23] oraz zdarzeń takich, jak zderzenia pojazdów, gwałtowne hamowanie czy dźwięk klaksonu [43, 116]. Dźwięk może również dostarczać informacje dotyczące typu pojazdu, kierunku jazdy oraz jego prędkości. W dynamicznym widmie dźwięku zawarta jest również informacja o typie i stanie nawierzchni. W kolejnych podrozdziałach każda z wcześniej przedstawionych modalności zostanie omówiona z odniesieniami do przeprowadzonych pomiarów akustycznych ruchu drogowego.

3.1 Hałas generowany przez poruszający się pojazd

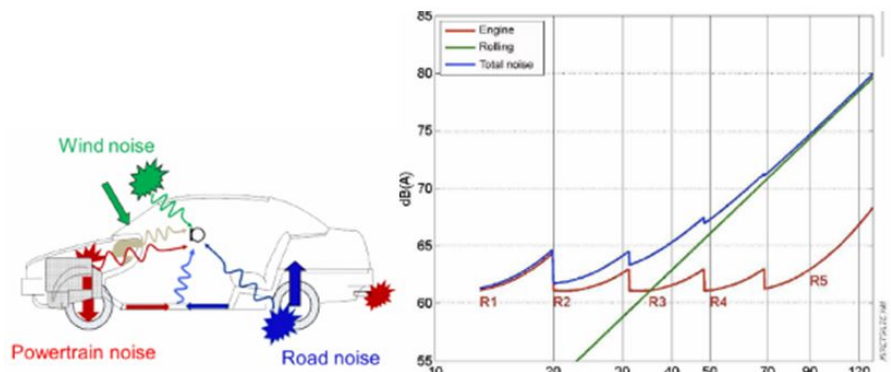
Charakter otoczenia drogi ma znaczący wpływ na własności propagacyjne i przekłada się na informacje zawarte w pomierzonym sygnale. W przypadku obszarów zurbanizowanych przejazd pojedynczego pojazdu może charakteryzować się wyższymi wartościami poziomu hałasu niż w przypadku dróg na odcinkach leśnych. Kluczowy jest stosunek powierzchni odbijających od pochłaniających.

Hałas generowany przez poruszający się pojazd jest wypadkową kilku składowych, których procentowy udział uzależniony jest od dynamicznych parametrów pojazdu i nawierzchni, jak i stałych parametrów pojazdu i drogi. Na rys. 3.1 przedstawiono wpływ poszczególnych parametrów pojazdu i warunków otoczenia na summaryczny wynik hałasu powstającego w chwili przejazdu [9, 14].



Rysunek 3.1: Parametry dynamiczne i stałe wpływające na wynikowy dźwięk generowany przez pojazd w ruchu


Innym sposobem opisu charakteru dźwięku poruszającego się pojazdu jest podział w odniesieniu do poszczególnych źródeł hałasu. Dominującym źródłem jest hałas toczenia związanego ze zjawiskiem interakcji opon pojazdu z nawierzchnią. Kolejnym źródłem jest hałas silnika i układu wydechowego. Przeważa on dla niższych prędkości i jest silnie powiązany z dynamicznymi parametrami ruchu pojazdu (w tym stylu jazdy kierowcy). Ostatnią grupę stanowią zjawiska aerodynamiczne, związane z prędkością pojazdu, jego wymiarami, oraz zewnętrznymi warunkami oraz siłą i kierunkiem wiatru w stosunku do kierunku jazdy. Siła oporów powietrza odgrywa znaczącą rolę dopiero w przypadku prędkości większych niż 150 km/h, dlatego nie będzie szczegółowo omawiana. Wymienione źródła oraz ich udział w zależności od prędkości pojazdu przedstawiono poglądowo na rysunku 3.2.



Rysunek 3.2: Rozkład źródeł poszczególnych hałasów w przypadku poruszającego się pojazdu[9, 127]

3.1.1 Hałas toczenia

Głównym źródłem hałasu generowanego przez poruszający się pojazd jest hałas toczenia spowodowany siłami tarcia między jezdnią i oponą. Poziom natężenia i jego charakter uwarunkowany jest też rodzajem perforacji na oponie (bieżnika), co przedstawiono na rys. 3.3. Im mniejsze perforacje, tym hałas jest mniejszy, jednak oznacza to mniejszą przyczepność w przypadku obecności wody na nawierzchni. Wartości techniczne ogumienia również mają wpływ na poziom hałasu: szerokość opony (im szersza, tym większy hałas), rodzaj i data produkcji i stopień zużycia opon (gęstość materiału). Wynikowy poziom hałasu zależy również od warunków atmosferycznych - temperatury nawierzchni, wilgotności i kierunku wiatru, jak i rodzaju nawierzchni, a dokładniej domieszki warstwy ściernalnej.



Rysunek 3.3: Proces generowania dźwięku toczenia: A - zetknięcie opony z podłożem, B - wibracje powietrza między żłobieniami bieżnika, C - wibracje przekazywane przed oponę do podłoża (grafika pochodzi ze strony michelintransport.com)

Ruch pojazdu po drodze związany jest z parametrami dynamicznymi pojazdu. Głównym czynnikiem jest siła napędowa silnika przekładana na oś (osie) napędowe pojazdu, jej wartość musi być na tyle duża, aby przeciwdziałać sile tarcia, oporowi powietrza i sile bezwładności pojazdu. W zależności od rodzaju drogi, jaką pokonuje pojazd, mogą dochodzić kolejne siły takie, jak siła oporu wzniesienia, siły związane

ze zmianami toru jazdy czy przemieszczenia się środka ciężkości pojazdu [34].

Siła napędowa pojazdu (PN) może być wyznaczona na podstawie ilorazu mocy maksymalnej silnika (NN[KW]), całkowitej sprawności pojazdu (η zależna od typu pojazdu i biegu jazdy) podzielonej przez prędkość (v) pojazdu w metrach na sekundę (wzór 3.1).

$$P_N = \frac{N_N \cdot 1000 \cdot \eta}{v} [N] \quad (3.1)$$

Zjawisko przełożenia mocy napędowej pojazdu na ruch postępowy zależy od warunków występujących na styku kół napędowych i nawierzchni. Dokładny wykaz czynników mających wpływ na wartość przyczepności pojazdu i tym samym generowany hałas toczenia przedstawiono w tabeli 3.1.

Tabela 3.1: Uwarunkowania związane z wartością współczynnika przyczepności

Parametry związane z oponą	Parametry związane z jezdnią	Parametry związane z warunkami pracy opony
- konstrukcja,	- rodzaj materiałów użytych do wykonania warstwy ścierniczej,	
- właściwości gumy bieżnika,	- tekstura nawierzchni,	- poślizg opony
- kształt i głębokość rzeźby bieżnika,	- zdolność do odprowadzania wody z jezdni,	względem jezdni,
- obciążenie koła,	- wilgotność,	- prędkość jazdy,
- ciśnienie powietrza w oponie.	- zanieczyszczenia (pyły, piasek),	- temperatura.
	- oblodzenie lub zaśnieżenie.	

3.1.2 Hałas silnika i układu wydechowego


Jak wspomniano wcześniej, dźwięk pojazdu przy niskich prędkościach warunkowany jest rodzajem i parametrami silnika. Obecnie obowiązujące normy regulują maksymalne poziomy hałasu, większość norm dotyczy jednak pomiaru pojazdu w otwartej przestrzeni i w odległości 7,5 m od osi wzdłużnej pojazdu [110]. Pomiar wykonuje się dla trzech prędkości: typowej - 50 km/h oraz dwóch uzależnionych od mocy silnika i prędkości obrotowej. Dopuszczalny poziom hałasu generowany przez pojazd w zadanych warunkach wynosi 82 dB(A) dla pojazdów osobowych. Maksymalny dopuszczalny poziom hałasu dla pojazdów powyżej 12 ton wynosi 91 dB(A). Unia Europejska zaleca dodatkowo normy ISO/TC 43/SC, regulują parametry toru pomiarowego, typu nawierzchni oraz jego właściwości pochłaniających [87].

Polska norma PN-92/S-04051 zakłada mierzenie pojazdu w trakcie postoju w terenie otwartym (brak przeszkód odbijających dźwięk). Nawierzchnia, na której badany jest stacjonarny pojazd może być asfaltowa, betonowa lub wykonana z innej twardej nawierzchni. Inne normy wymagają pomiaru w warunkach miejskich z zadaniem torem „U” [78, 109, 110].

Dźwięk silnika pojazdu jest traktowany przez duże koncerty motoryzacyjne



jako element kształtowania marki (tzw. branding) – może być chroniony prawem podobnie, jak typowe znaki towarowe (logotypy, kształt lamp czy też linia nadwozia). W zależności od charakteru pojazdu, modyfikowane jest brzmienie pojazdu – brzmienie luksusowe, sportowe czy też inne, np. bardziej agresywne brzmienia charakterystyczne dla amerykańskich pojazdów.



Rysunek 3.4: Schemat badania poziomu hałasu emisji układu wydechowego wg. normy PN-92/5-04051-3[109]

Aktualne ograniczenia nakładane na producentów silników sprawiły, że dźwięk różnych pojazdów upodabnia się do siebie. Normy Unii Europejskiej [64, 8, 133] spowodowały stopniowe wycofywanie silników o pojemnościach V6, V8. Głównym celem tych ograniczeń jest zmniejszenie emisji zanieczyszczeń, jednak przy tej okazji następuje też ograniczenie hałasu pochodzącego od silnika. W wyniku tych działań obserwuje się nowy trend. Niektórzy producenci decydują się na wdrażanie symulatorów brzemienia silników. Uzyskanie sportowego czy innego dźwięku nie jest jednak możliwe bez instalacji dodatkowych systemów akustycznych, naśladujących silniki wyższej klasy. Syntetyczne dźwięki pojazdów są regulowane parametrami jazdy. W zależności od danego rozwiązania, brzmienie silnika emitowane jest we wnętrzu pojazdu i/lub na zewnątrz.

Pojazdy elektryczne

Popularyzacja ekologicznych rozwiązań transportowych sprawiła, że coraz więcej pojazdów elektrycznych porusza się po drogach. Okazuje się, że pojazdy elektryczne – ze względu na brak emisji hałasu - mogą być niebezpieczne dla niechronionych użytkowników drogi przy niskich prędkościach.

Wymagania unijne nałożone na pojazdy elektryczne i hybrydowe wymagają instalowania urządzeń emitujących dźwięk do ostrzegania pieszych EVWS (ang. *Electric Vehicle Warning Sound*). Rozwiązania tego typu są jednak problematyczne, gdyż wymagają szeregu testów dotyczących detekcji dźwięku przez pieszych [123, 124, 125], tak aby spełniały swoje zadanie. Wymagania prawne dotyczące

ochrony przez hałasem drogowym


3.1.3 Wymagania prawne dotyczące ochrony przez hałasem drogowym

Zanieczyszczenie hałasem ma znaczący wpływ na zdrowie fizyczne i psychiczne mieszkańców. Według raportu przygotowanego w 2015 roku 14% światowej populacji zamieszkuje tereny zurbanizowane. Większość mieszkańców zamieszkuje większe aglomeracje, które są zarówno miejscem pracy, jak i rozrywki. Mieszkańcy miast są bardziej narażeni na stres (21% większe prawdopodobieństwo niż w przypadku osób mieszkających poza aglomeracjami)[93], przyczynia się do tego również poziom hałasu w miastach. Innym objawem zanieczyszczenia hałasem są zaburzenia pracy serca, depresja oraz zaburzenia snu [12, 28, 114].

Wzrost gospodarczy, przekładający się na zwiększenie liczby pojazdów (średnia liczba pojazdów na osobę) bez jednoczesnej poprawy akustycznych warunków mieszkaniowych sprawia, że coraz większa grupa mieszkańców znajduje się w grupie ryzyka zanieczyszczenia hałasem. Problemy związane z zanieczyszczeniem hałasem są regulowane dyrektywami i rozporządzeniami środowiskowymi [88, 135].

Dokumentowanie i analizowanie poziomów hałasu w miastach uregulowane jest wymaganiami unijnymi na mocy dyrektywy 2002/49/EC. Każde miasto spełniające warunki wymienione w ustawie zobowiązane jest do przygotowania analiz zanieczyszczenia hałasem w okresie co 5 lat. Dokumentacja powinna mieć charakter map akustycznych. W większości miast głównym źródłem hałasu jest hałas drogowy. Hałas, określany mianem zanieczyszczenia środowiska przekłada się również na zanieczyszczenie powietrza. W szczególności chodzi o emisje spalin, które powodują wzrost stężenia tlenu węgla (CO), pyły zawieszone (PM), tlenki azotu pochodzące głównie od pojazdów z napędem diesla (NOx). Unia Europejska wymaga więc przestrzegania ustalonych limitów emisji zanieczyszczeń przez nowo produkowane pojazdy, jak i te okresowo testowane i dopuszczane do ruchu [137].

Mapę akustyczną tworzy zestaw dokumentacji zawierający graficzne reprezentacje aktualnego stanu miasta z podziałem na poszczególne źródła hałasu (drogowy, szynowy, lotniczy i przemysłowy, przykłady zawarte na rys. 3.5), jak i szereg opracowań dotyczących planów minimalizacji zanieczyszczenia wraz z koniecznymi zmianami w planach zagospodarowania przestrzennego.



Rysunek 3.5: Poszczególne warstwy mapy hałasu miasta Gdańsk [138]


Rozdział 4

Wybrane metody uczenia maszynowego w akustyce

Słuch - jako jeden ze zmysłów ludzkich - dostarcza kluczowych informacji dotyczących otoczenia. Pomaga w rozpoznawaniu zdarzeń i obiektów i tym samym w ocenie potencjalnych zagrożeń. Słuch ludzki charakteryzuje się dużą zdolnością do słyszenia przestrzennego i selektywnego, w wyniku przetwarzania spercypowanego sygnału na poziomie ośrodkowym jest w stanie wyizolować źródło dźwięku, odseparowując automatycznie dźwięki niepożądane. Termin "uwaga, czujność" (ang. *attention*) odnosi się do procesu przetwarzania i interpretacji zaawansowanych scenarii akustycznych za pomocą zmysłów. Wyróżnia się dwa typy "uwagi słuchowej". Pierwsza z nich - zwana oddolną czy też zadaniowo-niezależną - określa reakcję człowieka na dźwięki wyróżniające się z tła. W przypadku ruchu drogowego może to przykładowo być dźwięk syreny alarmowej. Drugi typ reakcji - oddolny, zadaniowo-zależny polega na wyszukiwaniu konkretnego dźwięku w otoczeniu. Przykładowo pozwala skupić się na głosie rozmówcy (ang. *cocktail party effect*) w tle innych rozmówi dźwięków w pomieszczeniu.

Komputerowy system imitujący właściwości słuchu ludzkiego, w mniejszym lub większym stopniu jest w stanie osiągnąć podobny efekt. Opracowywane systemy mają za zadanie automatyczne rozpoznawanie wybranych dźwięków [61] lub, jak w przypadku algorytmów poprawiania zrozumiałości dialogów, wzmacniać je [32]. Obecnie temat ten jest najbardziej eksploatowany w systemach sterowania głosowego, np. w produktach światowych korporacji: Amazon (Alexa) [143], Asystent Google [46], Apple (Siri) [7, 20].

Pierwszym etapem w systemach CASA (ang. *Computational Auditory Scene Analysis*), posługując się analogią do działania ludzkiego słuchu, jest odseparowanie interesującego dźwięku z dźwięków otoczenia (Alain de Chevegné "The auditory system as a separation machine"). Czynność, będąca intuicyjną dla człowieka, nie jest tak łatwa w maszynowym słuchaniu (ang. *Machine Hearing*, MH). Skuteczność separacji związana jest m.in. z parametrami sygnału, jego rozdzielczością czasową, częstotliwościową, jak i stosunkiem sygnału do szumu. Obecnie istnieje co najmniej kilka podejść do uczenia komputerów słuchania i rozumienia dźwięku. Wspomniane we Wstępie obszary ACA, MH czy CASA, pomimo stosowania innych podejść, dążą do tego samego celu - analizowany sygnał foniczny powinien uzyskać nazwę – etykietę na wyjściu systemu klasyfikującego. Uproszczony schemat takiego podejścia przedstawiono na rys. 4.1.



Rysunek 4.1: Schemat działania systemów rozpoznawania otoczenia

Akustyczna analiza ruchu drogowego, pomimo iż jest przydatna jako metoda detekcji obecności pojazdu w scenie dźwiękowej, nie jest jeszcze powszechnie stosowana. Nie powstrzymuje to jednak zespoły badawcze w rozwijaniu możliwości takich systemów. Za pomocą detekcji i analizy dźwięku można łatwiej zwiększyć obszar monitorowania zdarzeń w ruchu drogowym niż za pomocą kamer wideo, co w przypadku autostrad i tuneli może mieć duże znaczenie.

Największe zainteresowanie monitoringiem akustycznym nad zdarzeniami pojawiło się w kontekście bezpieczeństwa w tunelach. Przykładem zastosowania takich systemów jest Austria, gdzie od 2010 roku prowadzone są pilotażowe programy nadzoru dźwiękowego [128]. Pierwszym tunelem, w którym zainstalowano akustyczny monitoring był tunel Kirchdorf o długości 2,4 km. Mikrofony zainstalowane w tunelach mają za zadanie reagować na odstępstwa - system reaguje na typowe dźwięki impulsowe związane z zderzeniami pojazdu ze ścianą tunelu lub innym pojazdem czy wykrywa dźwięk towarzyszący upadkowi bagażu z pojazdu. Czas zadziałania

systemu to wg jego twórców ok. 0,7 s, jednak decyzja dotycząca wszczęcia akcji ratowniczej czy zamknięcia pasa ruchu za pomocą sygnalizacji świetlnej zależy od operatora. Szeregowa instalacja mikrofonów w tunelu pozwala na łatwe określenie miejsca zdarzenia za pomocą różnic w poziomie natężenia dźwięku mierzonych przez poszczególne sensory. Zainstalowane mikrofony są odporne na zanieczyszczenia środowiskowe takie jak pył i wilgoć, co znacząco obniża koszt utrzymania systemu w porównaniu do monitoringu wizyjnego. W 2013 roku już 20 tuneli było wyposażonych w taki monitoring, a do 2019 roku planowane jest wyposażenie wszystkich 32 tuneli 3. i 4. klasy bezpieczeństwa w Austrii.

W kontekście komputerowej analizy dźwięku należy wyróżnić dwie główne gałęzie - pierwsza z nich obejmuje detekcję polegającą na estymacji punktu początkowego i końcowego w nagraniu, wyznaczającą położenie poszukiwanego dźwięku. Druga gałąź zajmuje się klasyfikacją, na podstawie wyznaczonych parametrów ramki czasowej nadaje odpowiednią etykietę (ang. *label, tag*) opisującą zawartość. AED (ang. *Acoustic Event Detection*) znajduje zastosowanie w wielu technologiach i obszarach techniki. Wymieniane na Wstępie narzędzia wspomagające ludzi niepełnosprawnych (ang. *Assistive technologies*) pozwalają osobom niedosłyszącym lepiej odnajdywać się w nieznanym środowiskach, wspomagają pamięć czy dbają o bezpieczeństwo osób z demencją. Także w dziedzinie bezpieczeństwa zauważalne jest duże znaczenie informacji pochodzącej do sygnałów akustycznych. Obecnie większość dostępnych kamer CCTV (ang. *Closed Circuit TeleVision*, kamery przemysłowe) wyposażona jest w mikrofony. Budowane są również sieci oparte jedynie na sieci czujników akustycznych wspomagających służby w wykrywaniu niebezpiecznych zdarzeń i przestępstw. W przemyśle również stosuje się metody nieingerencyjnej diagnostyki urządzeń [44, 95, 132]. W robotyce mikrofony wspomagają roboty autonomiczne w rozpoznawaniu otoczenia i podejmowaniu decyzji.

Obszar wyszukiwania muzyki *Music Information Retrieval* (MIR) obejmuje oprogramowanie i rozwiązania sprzętowe w tym zakresie. Łańcuch przetwarzania składa się z urządzeń rejestrujących próbki (mikrofon, smartfon), oprogramowanie zajmujące się przetwarzaniem wstępnym i transmisją zapytania na serwer, jak i usługą chmurową zajmującą się znalezieniem poprawnej odpowiedzi na zadane pytanie. Skuteczność systemu zależy od komunikacji między źródłem danych a systemem. Najprościej ujmując, zadanie polega na przetłumaczeniu opisu semantycznego źródeł dźwięku na język, którym operują systemy komputerowe, pozwalając przy tym na wielowymiarową analizę wykonywaną w ściśle określonym czasie [82].

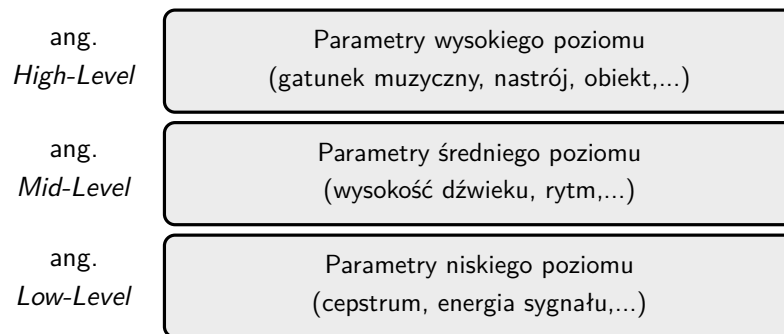
4.1 Ekstrakcja parametrów sygnału fonicznego

Sygnał foniczny w postaci cyfrowej jest wektorem $x[n]$ n -próbek sygnału, odzwierciedlającym zmianę poziomu ciśnienia dźwięku w funkcji czasu $p_a(t)$. Rejestrowane pasmo i dokładność odzwierciedlenia sygnału uzależnione jest od parametrów przetwarzania analogowo-cyfrowego.

Celem ekstrakcji - parametryzacji sygnału jest uzyskanie cech obiektów w postaci cyfrowej, możliwej do przetwarzania i „rozumienia” przez komputery. Proces ekstrakcji cech sygnału (ang. feature extraction) przebiega na podstawie zdefiniowanych równań matematycznych, zapewniając ich powtarzalność i deterministyczność. Efektem przekształceń mających na celu uzyskanie cyfrowego opisu k -tego obiektu (w rozumieniu powyższej rozprawy, sygnału fonicznego) jest wektor parametrów FV_k . Wektor ten można opisać za pomocą równania 4.1, gdzie wymiar i jest definicją przestrzeni wielowymiarowej zależnej od liczby ekstrahowanych parametrów [51].

$$X_k = FV_k = [v_1, v_2, \dots, v_i] \quad (4.1)$$

Parametry sygnałów akustycznych można podzielić na kilka typów, przy czym nie istnieje prosty i równocześnie jednoznaczny i przejrzysty sposób kategoryzacji parametrów dźwięku [74]. Bazując na opisie zawartym w standardzie MPEG-7, można podzielić parametry na cechy, deskryptory niskiego, średniego i wysokiego poziomu. Podział ten można przyrównać do stopnia interakcji zachodzącej pomiędzy człowiekiem i komputerem. W przypadku deskryptorów niskiego poziomu, mówi się o parametrach sygnału takich jak np. energia i jej rozkład w czasie, zmienność sygnału w czasie, itp. Przyjmuje się, że parametry te nie mają (nie muszą mieć) bezpośredniej interpretacji przez człowieka. Parametry średniego poziomu nawiązują do nazewnictwa muzycznego, w tym przypadku można odnieść się do wysokości dźwięku, barwy, rytmu dźwięku. Deskryptory wysokiego poziomu często są równoznaczne z zapisem formatu id3.2 [96, 92] i zwykle odnoszą się do etykiet zawierających informacje o gatunku muzycznym, wykonawcy muzyki, kompozytorze, itd. [5, 13, 74, 80].



Rysunek 4.2: Rozkład grup parametrów dźwięku, bazując na standardzie MPEG-7[74]

Stosując podejście sygnałowe, parametry dźwięku można podzielić na parametry czasowe, częstotliwościowe i czasowo-częstotliwościowe. Pierwszą grupę stanowią własności sygnału wyznaczone na podstawie czasowej reprezentacji sygnału. Zalicza się do nich między innymi energię sygnału, środek ciężkości sygnału, jego obwiednię czy gęstość przejść przez zero. Drugą grupę stanowią parametry wyznaczone na podstawie estymaty widma sygnału. Można wymienić widmową gęstość mocy (ang. *Power Spectral Density*, PSD), częstotliwość podstawową czy harmoniczną

sygnału. Dodatkowo, każdy z tych parametrów, szczególnie przy analizie czasowo-częstotliwościowej przedstawiany jest za pomocą opisów statystycznych: wartości średnich, odchylenia standardowego i momentów statystycznych.

Podejściem związanym z analizą sygnałów muzycznych jest również podział parametrów ze względu na dynamikę, rytm, wysokość, tonalność czy barwę. Analiza ruchu drogowego, sugeruje dodatkowo skorzystanie z miar związanych zarówno z oceną hałasu, jak i jakości dźwięku (ang. *Sound Quality*, SQ) [31].

Ekstrakcja cech jest najbardziej istotnym etapem procesu klasyfikacji, dokładność jego działania i czas trwania procesu jest uwarunkowana dobranymi cechami i ich reprezentacją. Sygnały analizowane są w ramach o długości K . Odpowiadać mogą one długości rzeczywistego sygnału lub można stosować podejście typu: *bag-of-frames* – dzieląc zdarzenie akustyczne na mniejsze ramki analizy (125, 250 ms). W przypadku analiz sygnału fonicznego, zaleca się, aby długość ramki była kolejną potęgą liczby dwa. Związane jest to z blokowym charakterem analizy Fouriera, sprzętowym podejściem do przesyłania sygnału fonicznego w ramach czy też alokacją pamięci. Dodatkowo, w analizach uwzględnia się operację zakładkowania ramek, oznacza to, że końcowe próbki ramki są równocześnie początkowymi próbkami dla następnej ramki (wzór 4.2). Wielkość parametru opisującego przeskok ramki przedstawiono we wzorze 4.3, typowo ustala się jego wartość na większą lub równą 50% [74].

$$\begin{aligned} i_s(n) &= i_x(n-1) + \mathcal{H}, \\ i_e(n) &= i_x(n) + \mathcal{K} - 1, \end{aligned} \quad (4.2)$$

$$o_r = \frac{\mathcal{K} - \mathcal{H}}{\mathcal{K}} \quad (4.3)$$

Uwzględniając czasową analizę sygnału, punktem startowym dla każdej ramki jest $t_s(n) = i_s(n)/f_s$, zależnym od częstotliwości próbkowania sygnału, ostatecznie sprowadzając się do równania 4.4

$$t_s(n) = \frac{i_e(n) - i_s(n) + 1}{2 \cdot f_s} + \frac{i_s(n)}{f_s} = \frac{\mathcal{K}}{2 \cdot f_s} + \frac{i_s(n)}{f_s} \quad (4.4)$$

Poza przytoczoną techniką podziału sygnału na ramki, dodatkowo stosować można analogiczną funkcję okna, która dodatkowo modyfikuje analizowaną ramkę sygnału. Funkcję okna można opisać za pomocą równania 4.5.

$$Q_n = \sum_{k=-\infty}^{\infty} \tau(s(k))w(n-k) \quad (4.5)$$

gdzie:

$s(k)$ - wartość analizowanego sygnału w czasie k ,

$\tau(\cdot)$ - użyta transformacja na sygnale,



$w(n)$ - okno, lub funkcja wagowa,

Przystępując do analizy zbioru krótkich sygnałów, często operuje się różnych poziomach analizy. Na etapie przetwarzania wstępnego (*pre-processingu*) zwykle stosuje się normalizację. Umożliwia to np. sprowadzenie wartości amplitudy do przyjętej wartości maksymalnej (wzór 4.6), nie zapewnia to jednak zachowania jednakowej głośności (rozumianej jako *loudness level* 4.1.3), dodatkowo wprowadzając ryzyko zniekształceń typu „przycinanie sygnału” (ang. *clipping*), trzaski (ang. *crackles*). Inną metodą jest normalizacja względem wartości skutecznej sygnału (*RMS* lub *Loudness Level*). Tego typu metody normalizacji sygnału stosowane są jedynie do analizy *offline* [74].

$$x(i) = \frac{x_s(i)}{\max_{\forall t}(|x_s(i)|)} \quad (4.6)$$

W przypadku małych zbiorów danych analizuje się typowo reprezentacje liczbowe poszczególnych parametrów. W przypadku dużych zbiorów danych, obecnie często stosuje się klasyfikację na podstawie graficznej reprezentacji dźwięku (spektrogramy, chromagramy itp)[26, 40]. Spowodowane jest to zasadą działania splotowych sieci neuronowych (ang. *Convolutional Neural Networks, CNN*)[115].

Badania nad nowymi systemami akustycznej analizy ruchu drogowego prowadzone są od lat 90. ubiegłego wieku. Ze względu na dostępne wtedy zasoby technologiczne i komputerowe, jako metody klasyfikacyjne stosowano głównie drzewa decyzyjne, GMM i *k*-NN. Z kolei najczęściej uwzględniane parametry obejmowały: energię sygnału, środek ciężkości widma i parametry mel-cepstralne. Szczegółowo przedstawiono to w tabeli 4.1.

Tabela 4.1: Przegląd dotychczasowych badań w dziedzinie rozpoznawania dźwięków pojazdów

Przegląd dotychczasowych badań w dziedzinie rozpoznawania dźwięków pojazdów	
Parametr	Znaczenie
Spina, Zue (1996)	Parametry cepstralne, 14 parametrów melcepstralnych;
Lui et al. (1998)	Częstotliwość podstawowa, pasmo sygnału, Energia sygnału w podpasmach;
Hansen i Womack (1996)	Parametry cepstralne, autokorelacja parametrów melcepstralnych (AC-Mel);
Zhang i Kuo (1999)	Energia sygnału w ramkach, gęstość przejść przez zero, częstotliwość podstawowa;
Li i Dimitrowa	Krótkookresowa energia sygnału, częstotliwość podstawowa, środek ciężkości widma, częstotliwość, poniżej której skumulowane jest wzmocnienie STFT $X(k,n)$ (spectral roll-off frequency), energia w podpasmach;
Wold i Blun et al.	Krótkookresowa energia sygnału, pasmo sygnału, środek ciężkości widma, wybrzmiewanie (spectral roll-off frequency), energia w podpasmach;
Pfeiffer et al. (1996)	Pomiar pulsacji w sygnale, częstotliwość podstawowa,

Kontynuacja tabeli 4.1

Parametr	Znaczenie
Fisher et al. (1995)	Pomiar pulsacji w sygnale, spektrogram widma;
Patel i Sethi (1996)	Pulsacja, stosunek energii w podpasmach;
Saraceno i Leonardi (1997)	Gęstość przejść przez zero;
Scheirer i Slaney (1997)	Gęstość przejść przez zero, środek ciężkości widma, <i>spectral roll-off frequency</i> , 13 cech czasowych i widmowych (<i>temporal and spectral features</i>);
Wold i Blun et al. (1996)	Harmoniczność sygnału, częstotliwość podstawowa

4.1.1 Wybrane parametry z dziedziny czasu i częstotliwości i ich charakterystyki statystyczne

Energia sygnału

Energia sygnału jest wyznaczana za pomocą kwadratu sumy wartości próbek sygnału (wzór 4.7). W praktyce, częściej wykorzystywana jest wartość skuteczna RMS wyznaczana jako pierwiastek wartości średniej energii sygnału (wzór 4.8).

$$E = \sum_n x^2(n) \quad (4.7)$$

$$X_{sk} = \sqrt{\frac{1}{N} \sum_{n=1} x^2(n)} \quad (4.8)$$

Krótkookresowa energia sygnału:

$$E(\hat{n}) = \sum_{m=-\infty}^{\infty} (x[m]w[\hat{n}-m])^2 = \sum_{m=-\infty}^{\infty} (x[m])^2 \tilde{w}[\hat{n}-m] \quad (4.9)$$

Środek ciężkości widma

Parametr jest związany z obwiednią sygnału, wyznaczany za pomocą wzoru 4.10. Jest on oznaczany za pomocą skrótu TC oznaczającego Temporal Centroid (MPEG-7).

$$TC = \frac{\sum_{n=1}^N n \cdot O(n)}{\sum_{n=1}^N O(n)} \quad (4.10)$$

gdzie:

$$O(n) = o_1, o_2, \dots, o_N$$

$$o_n = \sqrt{\frac{1}{K} \sum_{k=1}^K x_n^2(k)}$$


Gęstość przejść przez zero

Gęstość przejść przez zero (ang. *Zero Crossing Ratio*, ZCR) jest parametrem opisującym zmienność sygnału w dziedzinie czasu (wzór 4.11) [120]. Algorytm wyznacza liczbę c przejść sygnału $x(t)$ przez zadaną wartość (typowo zero, rys. 4.3). Wartość podawana jest dla zadanego okresu obserwacji. Przy porównywaniu wartości między sygnałami należy zwracać szczególną uwagę na długość okna analizy poszczególnych próbek. W przypadku wyznaczania parametru typowo stosowane jest okno prostokątne. Duża wartość parametru ZCR może wskazywać na dużą zawartość wysokich częstotliwości. Dźwięki harmoniczne, zazwyczaj posiadają niską wartość ZCR, zaś tony - wartość zerową [30, 39, 116].

$$Z_n = \sum \left| \text{sgn}[x(m)] - \text{sgn}[x(m-1)] \right| w(n-m) \quad (4.11)$$

Gdzie:

$$\text{sgn} |x(n)| = \begin{cases} 1 & x(n) \geq 0 \\ -1 & x(n) < 0 \end{cases}$$



Rysunek 4.3: Parametr ZCR zlicza momenty, w których amplituda sygnału zmienia znak


Parametry statystyczne

W kontekście sygnału zarówno w dziedzinie czasu jak i częstotliwości można dodatkowo analizować ich statystyczne rozłożenie, czy to w obrębie pojedynczej ramki sygnału czy też w kontekście zagregowanej ramki reprezentującej izolowane zdarzenie akustyczne. Miary te można podzielić na miary zmienności, tj. odchylenie standardowe, wariancja, asymetria (skośność) i sygnał zgodny (lub nie) z rozkładem Gaussowskim (kurtoza).

- **środek ciężkości widma** (ang. *spectral centroid*, unormowany moment pierwszego rzędu), z kolei moment zwykły pierwszego rzędu (ang. *Center of gravi-*

ty) wyznaczany jest na podstawie indeksowanej sumy ważonej wartości wektora dzielonej przez nieważoną sumę wartości w sygnale. Środek ciężkości widma jest skorelowany z barwą dźwięku, na tej podstawie określa się jasność czy chropowatość dźwięku 4.1.1;

- **skośność widma** (ang. *skewness*, unormowany moment centralny trzeciego rzędu). Skośność związana jest ze zjawiskiem asymetrii rozkładu energii w sygnale. Dla sygnałów symetrycznych (rys. 4.4 a)) wartość tego parametru wynosi zero, natomiast w zależności od kierunku, w którym ta wartość się przesuwają, określana jest jako skośność lewo- lub prawostronna. W przypadku analizy skośności widmowej (ang. *spectral skewness*), parametr ten wyznacza rozkład widma wokół jego symetrycznej średniej. Dla sygnału czysty jego wartość wynosi 0, dla szumu białego jest wartością stałą.



Rysunek 4.4: Rozkłady skośności sygnału $D(x)$ względem wartości średniej \bar{x} i mediany $Me(x)$ [91]

- **kurtoza widma** (ang. *kurtosis*) wyznaczany na podstawie unormowanego momentu centralnego rzędu 2. i 4. Za pomocą kurtozy można zmierzyć, w jaki stopniu analizowany sygnał odbiega od rozkładu Gaussowskiego. Przy sygnale zbliżonym do rozkładu Gaussowskiego, wartość parametru wynosi zero, gdy jego wartość jest ujemna – sygnał ma płaski rozkład. Wartości dodatnie parametru świadczą o zawartości wartości szczytowych w sygnale (wzór 4.12) [74].

$$K = \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{s} \right)^4 - \frac{2(n-2)^2}{(n-2)(n-3)} \quad (4.12)$$

Gdzie:

K - kurtoza,

n - liczba obserwacji,

x_i - poszczególne obserwacje, wyniki z próby

\bar{x} - średnia wyników, z próby

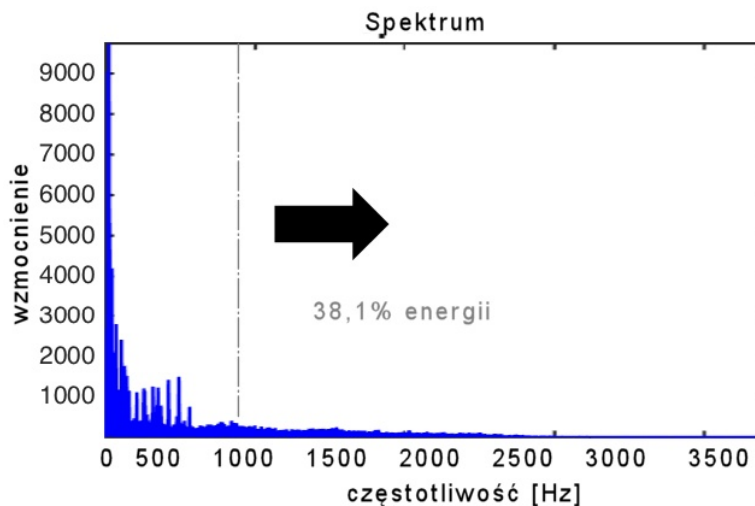
s - odchylenie standardowe

Wśród pozostałych parametrów widmowych warto wymienić płaskość widmową (ang. *Spectral Flatness Measure*, SFM). Parametr ten jest wyznaczany na podsta-

wie stosunku średniej geometrycznej i arytmetycznej współczynników widma. Określany jest jako miara harmonicznego sygnału. Spectral Rolloff $v_{SR}(n)$ definiowany jest jako częstotliwość, poniżej której skumulowane jest wzmocnienie $STFTX(k, n)$ osiągając zadany procentowy udział w sumie energii sygnału. Typowo stosowane progi odpowiadają wartościom: 85% i 95%. Wartość $v_{SR}(n)$ może być łatwo zamieniona na wartość w Hz lub może być przedstawiana jako wartość z zakresu 0-1 poprzez normalizację względem wymiaru $STHF(k/2 - 1)$. Niskie wartości parametru Rolloff oznaczają małą zawartość wysokich częstotliwości w sygnale.

Jasność (ang. *Brightness*)


O jasności dźwięku decyduje zawartość energii w poszczególnych pasmach. Im większa jej część skupia się w wysokich częstotliwościach, tym dźwięk wydaje się subiektywnie jaśniejszy lub bardziej jaskrawy (ang. *sharpness*, Juslin(2000)). Najczęściej przyjmowaną wartością progową jest 1500 Hz (Julian, 1999 r.).



Rysunek 4.5: Zobrazowanie parametru *brightness* [69]

Energia sygnału w niskim paśmie (ang. *Low Energy*)

Przeciwnym znaczeniowo parametrem jest *Low-energy*, który odpowiada za informacje, jaka część energii sygnału znajduje się w niskim paśmie. Typowe wartości progowe to 250, 500 Hz. Jest to parametr pośrednio powiązany z dynamiką dźwięku. Obiektywnie wyznaczany jest na podstawie udziału ramek sygnału, w których energia sygnału jest niższa niż średnia energia próbki (Tzanetakis and Cook, 2002). Wartość parametru zależy od długości ramki analizy, stopnia zakładowania oraz ustalonego progu reakcji.



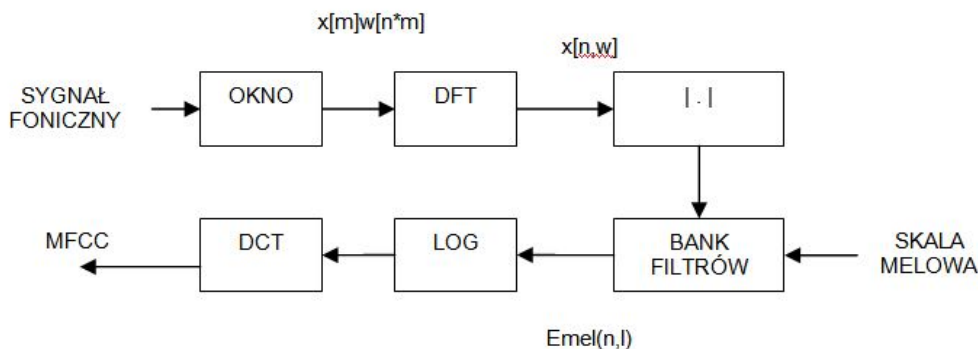
Rysunek 4.6: Zobrazowanie parametru *low energy* [69]

Oba parametry z grupy MIR są ściśle powiązane z centroidem widma (*ang. Spectral Centroid*). Czyli inaczej środek ciężkości widma reprezentowany przez wartość częstotliwości wokół której skupia się energia sygnału. Wartość tę można wyznaczyć za pomocą wzoru 4.13.


$$f_c = \frac{\sum_k S(k)f(k)}{\sum_k S(k)} \quad (4.13)$$

Parametry mel-cepstralne (*ang. Mel-Frequency Cepstral Coefficients*)

Zastosowanie parametrów mel-cepstralnych jest często wykorzystywane w automatycznym rozpoznawaniu sygnałów fonicznych i pozwala na uzyskanie dużej skuteczności w systemach automatycznej analizy mowy, jak i w realizacjach systemów akustycznej detekcji ruchu drogowego. Współczynniki mel-cepstralne wyznaczane są na podstawie krótkookresowej transformacji Fouriera i filtracji z zastosowaniem skali melowej 4.7. Parametry te są silnie związane z psychofizycznym postrzeganiem dźwięku przez człowieka. Filtry melowe przedstawiono na rys. 4.8, a wyznacza się je na podstawie wzoru 4.14



Rysunek 4.7: Schemat wyznaczania parametrów mel-cepstralnych



Rysunek 4.8: 10 filtrów melowych pokrywających pasmo od 0-8 kHz

$$c_n = \sqrt{\frac{2}{K}} \sum_{k=1}^K (\log S_k) \cos [n(k - 0,5)\pi/K], \quad n = 1, 2, \dots, L \quad (4.14)$$

Gdzie:

L - numer kolejnego cepstrum,

K - numer filtru.

4.1.2 Parametry związane z oceną hałasu źródła

Dyrektywy Unii Europejskiej [135], dotyczące kontroli zanieczyszczenia emisją hałasu miast, wymusiły instalacje stałych punktów monitoringu środowiska. Korzystając z danych pomiarowych oraz modeli algorytmicznych wyznaczających poziom hałasu, możliwe jest wyznaczenie estymowanej liczby pojazdów w zadanych przedziałach czasu na podstawie dostarczonych parametrów statycznych i dynamicznych badanego obszaru.

W latach 2014-2016 [21, 65, 83, 86] opracowano metodologię wyznaczania dynamicznych map hałasu, na podstawie estymowanej liczby pojazdów pochodzącej z czujników hałasu rozmieszczonych na terenie Gdańska. Dane dotyczące natężenia ruchu na poszczególnych trasach w mieście, wyznaczone były na podstawie godzinowych wartości hałasu L_{A1Heq} . Jest to równoważny poziom hałasu, skorygowany według krzywej korekcji A , wyznaczany zgodnie z Polską Normą (wg. PN-ISO 1996-1)[98] w odniesieniu do 1 godziny ekspozycji.

Do wyznaczania poziomu hałasu stosować można krótkookresowe wartości poziomu dźwięku L_{Aeq} , L_{p2p} [84].

$$L_{Aeq} = 10 \log \left[\frac{1}{t_2 - t_1} \int_{t_2}^{t_1} \frac{p_A^2}{p_0^2} dt \right] dB \quad (4.15)$$

Gdzie:

p_0 - poziom ciśnienia odniesienia ($2 * 10^{-5} Pa$),

p_A - chwilowa wartość poziomu ciśnienia akustycznego A , mierzonego sygnału akustycznego.

Do pozostałych norm, zalecanych i przyjętych do stosowania w Polsce, należy wymienić:

- ROZPORZĄDZENIE MINISTRA ŚRODOWISKA z dnia 29 lipca 2004 r. w sprawie dopuszczalnych poziomów hałasu w środowisku Dz. U. nr 178 poz. 1841.
- PN-81/N-01306 Hałas. Metody pomiaru.
- PN-94/N01307 Hałas. Dopuszczalne wartości hałasu w środowisku pracy.
- PN-ISO 1996-2/1999 Akustyka. Opis i pomiary hałasu środowiskowego. Zbieranie danych dotyczących sposobu zagospodarowania terenu.
- PN-ISO 1996-3/1999 Akustyka. Opis i pomiary hałasu środowiskowego. Wytyczne dotyczące dopuszczalnych poziomów hałasu

Poziomy hałas uwzględniane w mapach akustycznych, przywołane w rozdziale 3.1.3, odnoszą się głównie do miar długookresowych - w odniesieniu do pory nocnej, dnia roku. Ich wartości mogą jedynie sugerować wstępne wartości progu reakcji systemu wykrywającego pojazdy.

4.1.3 Parametry jakości dźwięku (Sound Quality)

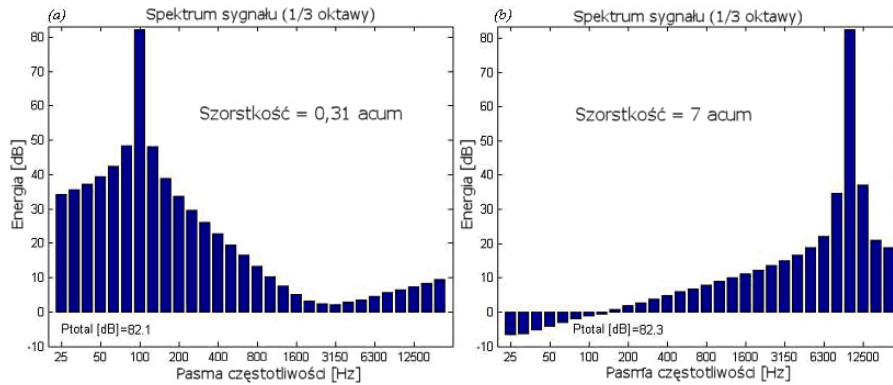
Głośność (ang. *Loudness Level*)

Parametr głośność jest odniesieniem do psychoakustycznego postrzegania dźwięku przez człowieka. Daje lepsze rezultaty niż zastosowanie filtra A przy badaniu wrażenia głośności poszczególnych dźwięków. Parametr to wyznaczania poziomu głośności wykorzystuje stałe barkową (wzór 4.16).

$$N = \int_0^{24Bark} N' dz \quad (4.16)$$

Szorstkóść (ang. *Sharpness*)

Szorstkóść służy do wyznaczenia zawartości wysokich częstotliwości w sygnale wyznaczane za pomocą jednostki *acum*. Im jego wartość większa, tym bardziej szorstkie brzmienie ma dźwięk (rys. 4.9). Miara ta używana jest przy ocenie jakości sprzętu gospodarstwa domowego, a w motoryzacji do badania hałasu generowanego przez układ wydechowy silnika.



Rysunek 4.9: Spektrogram sygnału i wartość miary szorstkości brzmienia [115],

Pierwsze prace nad wyznaczaniem tej miary podjęli Zwicker i Fastl [31], określając 1 *acum* jako wąskopasmowy hałas o szerokości jednego pasma krytycznego o częstotliwości środkowej 1kHz i poziomie 60 dB. W tej postaci szorstkość można wyznaczyć za pomocą wzoru 4.17, choć miara nie doczekała się standaryzacji i w pomiarach można spotkać różne modyfikacje tej miary.

$$S = c \cdot \frac{\int_0^{24Bark} N' g'(z) \cdot z \cdot dz}{\int_0^{24Bark} N' dz} \quad (4.17)$$

Chropowatość (ang. *Roughness*)

Chropowatość rozumiana jest jako szybkie (15-200 Hz) modulacje amplitudy dźwięku. Ton o częstotliwości 1000 Hz, i poziomie 60 dB zmodulowany z częstotliwością 70 Hz daje wartość 1 aspera. Częstotliwość modulacji ograniczona jest właściwościami słuchu ludzkiego. Parametr ten stosowany jest do oceny jakości brzmienia silników samochodowych, elektroniki użytkowej. Wysoka wartość parametru sugeruje iż dźwięk może wywoływać uczucie rozdrażnienia lub dyskomfortu u użytkowników [47, 139].

$$R = cal \cdot \int_0^{24Bark} f_{mod} \cdot \Delta L \cdot dz \quad (4.18)$$

$$R = cal \cdot \sum_0^{24Bark} g(z_i) \cdot m_i^* \quad (4.19)$$

Siła fluktuacji (ang. *Fluctuation strength*)


Siła fluktuacji w sygnale jest podobnym parametrem do szorstkości, odnosi się jednak do wolniejszych modulacji amplitudy (do 20 Hz). Jednostką fluktuacji jest *vacil*. Tak jak przy parametrze *roughness* odpowiada 4 Hz modulacji tonu o wysokości 1000 Hz i poziomie 60 dB [31]. Wartość tego parametru wyznaczana jest na podstawie równania 4.20, gdzie ΔL oznacza głębokość maskowania (nie modulacji), zaś (f_{mod}) oznacza częstotliwość modulacji.

$$F = \frac{0.008 \cdot \int_0^{24Bark} \Delta L \cdot dz}{\left(\frac{f_{mod}}{4Hz}\right) + \left(\frac{4Hz}{f_{mod}}\right)} \quad (4.20)$$

4.1.4 Graficzne reprezentacje sygnałów dźwiękowych

Zainteresowanie w dziedzinie sieci neuronowych (uczenie głębokie) spowodowane jest obecnie nowymi możliwościami sprzętowymi. Zastosowanie klastrów obliczeniowych czy procesorów graficznych do obliczeń głębokich sieci neuronowych pozwala na wykorzystanie danych również w postaci graficznej. Zamiast dostarczania wektora parametrów przedstawiana jest graficzna postać sygnału na wejściu sieci. Najczęściej stosowaną postacią są spektrogramy. W kontekście analizy parametrów ruchu drogowego na podstawie spektrogramu można ocenić, jakie źródło hałasu było analizowane, jaka była prędkość pojazdu i stan nawierzchni, itd.

Sygnal foniczny można przedstawić za pomocą typowego przebiegu czasowego (ang. *waveform*), będącego wizualizacją zmian natężenia sygnału w czasie. Obrazowaniem łączącym postać czasową i częstotliwościową sygnału jest spektrogram, wizualizowany za pomocą pseudo-trójwymiarowego wykresu. W literaturze w procesie rozpoznawania zdarzeń akustycznych wykorzystuje się spektrogramy w skali logarytmicznej, melowej [74]. Przykładowe spektrogramy dla sygnału przejazdu pojazdu osobowego i pojazdu uprzywilejowanego z uruchomioną syreną przedstawiono na rys. 4.10.



Rysunek 4.10: Przykładowe spektrogramy: po lewej - przejazd karetki pogotowia przy dużym zagęszczeniu ruchu; po prawej - indywidualny przejazd pojazdu osobowego przy małym natężeniu ruchu

Kolejną metodą wizualizacji sygnałów są chromagramy, gammatony przedstawiające poziom natężenia sygnału w poszczególnych podpasmach sygnału [3, 74, 97, 147].

Filtry Gammatone (ang. *gammatone filter*)

Filtry gammatone, podobnie jak gammachirp, są to filtry o zdefiniowanej odpowiedzi impulsowej, pozwalające na filtrację w dziedzinie czasu [147]. Filtry stanowią odpowiedź impulsową złożoną z funkcji gamma odpowiadającej obwiedni odpowiedzi impulsowej i przebiegu tonu o zadanej częstotliwości f_c lub częstotliwości przestrajanej w czasie (*gammachirp*). Parametry filtrów dobierane są w taki sposób, aby ich charakterystyka amplitudowa była zbliżona do charakterystyki filtru *Roex*(p, r) (wzór 4.21, rys. 4.11). Filtry gammatone zalecane są do analizy niskich i średnich poziomów sygnału, z kolei gammachirp dla sygnałów oscylujących wokół 90 dB. Filtry gamma odnoszą się do właściwości słyszenia. Wynik filtracji dla przykładowego dźwięku przejazdu pojazdu przedstawiono na rys. 4.12.

$$gammatone(t) = at^{n-1}e^{-2\pi bERB(FCc)t} \cos(2\pi f_c t + \Phi), t > 0 \quad (4.21)$$

gdzie:


f_c - częstotliwość środkowa filtru,

ERB - równoważna szerokość prostokątna filtru,


t - czas,

n - rząd funkcji gamma,

a, b, c - stałe.



Rysunek 4.11: Odpowiedzi filtrów gammatone




Rysunek 4.12: Wynik operacji gammatone dla przejazdu pojazdu z niskoczęstotliwościowym zakłóceniem

4.2 Wybrane metody uczenia maszynowego w przetwarzaniu dźwięku

W oparciu o zasadę uczenia systemu można systemy uczące można podzielić na działające w oparciu o zapamiętywanie, podejmowanie decyzji na podstawie instrukcji, analogię, indukcję i dedukcję [129]. Inny podział systemów uczenia maszynowego zależy od przyjętych sposobów pozyskiwania wiedzy lub rodzaju informacji dostarczonej na etapie uczenia. Wyodrębnia się dwie główne grupy: uczenie z nadzorem (ang. *supervised learning*) i uczenie bez nadzoru (ang. *unsupervised learning*).

Tabela 4.2: Podział różnych rodzajów uczenia maszynowego (ML) w akustyce z podziałem na ich zastosowanie i wynik działania

Kategoria	Przykład a)	Przykład b)	Zastosowanie
Rozpoznawanie otoczenia	 PARK	 ULICA	wspomaganie osób niepełnosprawnych, roboty autonomiczne
Rozpoznawanie izolowanych zdarzeń	kroki, śpiew ptaków, śmiech, szum drzew, dzwonek rowerowy,	samochód, klakson samochodowy, karetki,	systemy alarmowe, detektory
Detekcja czynności	jazda na rowerze	spacer	wspomaganie osób starszych,

Systemy automatycznej klasyfikacji wykorzystują binarny opis cech obiektu

czy też zdarzenia, który jest zrozumiały dla komputerów. Przeniesienie często fizycznych lub w przypadku automatycznej klasyfikacji dźwięku - psychoakustycznych cech na reprezentacje liczbowe umożliwia dalsze operacje, jak i porównywanie obiektów w danej populacji. Im więcej cech opisuje dany obiekt, tym większe istnieje prawdopodobieństwo znalezienia cech umożliwiających jednoznaczne rozróżnienie przedmiotów przynależnych do innych populacji. Jednak w miarę rozbudowywania słownika cech dla danego obiektu rośnie złożoność obliczeniowa, wydłużając czas klasyfikacji, co może być kluczowe w systemach, które powinny działać w czasie rzeczywistym. Łatwiej też wtedy o przetrenowanie systemu czy też wyznaczenie fałszywych korelacji, nie mających rzeczywistego odniesienia do badanego zjawiska. W systemach stosuje się więc algorytmy redukcji wektora cech (4.3.2). Koszt obliczeniowy zależy co najmniej liniowo od rozmiaru przetwarzanego zbioru danych [50, 53, 131].

Uczenie nadzorowane polega na opracowywaniu funkcji f spełniającej dla każdego i warunek:

$$f(x_i) = y_i \quad (4.22)$$

gdzie:

x_i - i -ta obserwacja,

y_i - i -ty wyniki obserwacji.


Cecha opisująca obiekt typowo oznaczana jest małą literą, dziedziczoną po wielkiej literze określającej populację. W klasyfikacji zdarzeń drogowych występują zarówno zmienne katagoryczne (jakościowe, ang. *qualitative*), jak i numeryczne (ilościowe, ang. *quantitative*) [50, 131]. Zbiór obserwacji ich cech przedstawia się typowo za pomocą tabel lub macierzy (wzór 4.23).

$$j\text{-ta obserwacja} \left\{ \begin{array}{ccc} x_{11} & \cdots & x_{1i} \\ \vdots & \ddots & \vdots \\ x_{j1} & \cdots & x_{ji} \end{array} \right\} \quad (4.23)$$

i -ta cecha

Omawiane metody uczenia maszynowego usystematyzowano na grafie 4.13. Uczenie nadzorowane można podzielić na modele regresyjne i klasyfikacyjne. Ich zadaniem jest predykcja wartości atrybutu decyzyjnego (na potrzeby rozprawy oznaczone jako y_j), przy czym w systemach regresyjnych, wartość y_j jest liczbą rzeczywistą, zaś przy klasyfikacji – zmienną jakościową [38, 76, 129], np. - maszyna wektorów nośnych (SVM - ang. *Support Vector Machine*). Uczenie nienadzorowane dzieli się na analizę skupień (klasterową) - dzielącą zbiory wg. podobieństwa cech i modele


stosowane do redukcji wymiarowości, np. metoda PCA - ang. *Principal Component Analysis*.



Rysunek 4.13: Klasyfikacja systemów uczenia maszynowego

W większości omawiane systemy działające w akustyce powstają w oparciu o indukcję, tj. na podstawie dostarczonych przykładów tworzą pewną uogólnioną postać obiektu. Termin klasyfikacja (ang. *classification*) odnosi się do podziału zbioru obiektów (przykładów) na klasy (kategorie). W przypadku systemów związanych z rozpoznawaniem dźwięku, można wydzielić trzy główne gałęzie: rozpoznawanie otoczenia, izolowanych wydarzeń oraz wykonywanej czynności. Przykłady użycia i obszary zastosowania przedstawiono w tabeli 4.2.

Metody regresyjne stosowane typowo są w przypadku predykcji miar typu ilościowego, zaś miary jakościowe są wynikiem metod klasyfikacyjnych. Oba te procesy łączy wiele wspólnych cech i obie mogą być stosowane przy aproksymacji. Część z metod może stosować mieszany zbiór danych – zarówno określone jakościowo, jak i ilościowo. Każda z metod ma za zadanie rozróżnić grupy obiektów za pomocą pewnego predyktowanego podziału. Za pomocą typowych wykresów rozrzutu będących wizualizacją separowalności klas przedstawiono wyniki dla wybranych metod uczenia 4.14.



Rysunek 4.14: Wizualizacja działania wybranych metod uczenia maszynowego w kontekście separowalności klas za pomocą wykresu rozrzutu [141]

Postać danych

W przypadku systemów decyzyjnych, kluczowym etapem jest przygotowywanie zbioru treningowego i jego reprezentacja [53, 91]. W większości przypadków problem rozpoznawania źródeł dźwięku nie będzie odnosił się do zapytania binarnego. Sama postać etykiety obiektu zazwyczaj będzie również przedstawiana za pomocą wyrazów, które na potrzeby części systemów decyzyjnych należy przepisać na postaci liczbowe. Kluczowa może być kolejność nadawania liczbowych etykiet (wzory 4.2 czy też ich forma: wektor/liczba).

$$Y = \begin{cases} 1 & \text{ifzawał} \\ 2 & \text{ifprzedawkowanie;} \\ 3 & \text{ifpadaczka.} \end{cases} \quad Y = \begin{cases} 1 & \text{ifpadaczka;} \\ 2 & \text{ifzawał;} \\ 3 & \text{ifprzedawkowanie.} \end{cases}$$

Przygotowując dane w kontekście trenowania sieci neuronowych, przyjęło się stosowanie wektora odpowiedzi. Na przykładzie analizy sygnału pochodzącego od pojazdu osobowego przy założeniu że zakłada się, że analizowany pojazd może nale-

żeć do jednej z pięciu klas pojazdów (motocykl, osobowy, mały dostawczy, dostawczy, tir/autobus], wektor odpowiedzi dla zadanego wektora cech będzie miał następującą postać: $Y = [0, 1, 0, 0, 0]$

4.2.1 Drzewa decyzyjne

Drzewa decyzyjne należą do jednych z prostszych systemów decyzyjnych. Prezentowane są jako graficzna reprezentacja w postaci drzewa. Korzeń odpowiada możliwym odpowiedziom systemu, węzły zaś odpowiadają za decyzje przypisane do liści. Algorytm ten stosowany jest również do redukcji ilości danych, analizy zależności parametrów między wyjściem klasyfikatora oraz w eksploracji danych (ang. *data mining*).

Prawidłowa konstrukcja drzewa jest często wynikiem iteracyjnym – dążącym do uzyskania najmniejszej straty. Jedną z metod optymalizacji drzew decyzyjnych jest entropia (4.24, podobnie jak w teorii informacji reprezentowana za pomocą średniej ilości informacji przypadającej na znak oznaczający i -te zdarzenie ze zbioru.

$$H(x) = \sum_{i=1}^n p(i) \log \frac{1}{p(i)} = - \sum_{i=1}^n p(i) \log p(i) \quad (4.24)$$

gdzie:

$p(i)$ - prawdopodobieństwo zajścia zdarzenia i .

Wartość entropii należy wyznaczyć dla każdego przypadku, wartość 0 oznacza koniec konaru drzewa. Innym parametrem charakterystycznym dla drzew decyzyjnych jest zysk/przyrost informacyjny (ang. *information gain*, IG). Opisuje on wartości informacyjne drzewa przed/po podziale na dodatkowe gałęzie. Wyróżnia się drzewa proste i skośne [91, 53].

4.2.2 k -najbliższych sąsiadów (k -NN)

Algorytm k -najbliższych sąsiadów jest jednym z algorytmów regresji nieparametrycznej. Główną ideą działania jest wyznaczanie najbliższych obiektów od analizowanej obserwacji. Miarą odległości d_{ji} od poszczególnych obiektów j i k jest przykładowo odległość euklidesowa wyznaczana za pomocą wzoru 4.25 lub metryka miejska (Manhattan) przedstawiona za pomocą wzoru 4.26. Wynik określany jest w oparciu o głosy większości z k -najbliższych sąsiadów. W zależności od wartości k uzyskuje się inne obszary podziału, mniejszą wrażliwość na szумы i artefakty. Prowadzić to jednak może do błędów w klasyfikacji mniej licznych wzorców, uzyskując zbyt dużą generalizację [53].

$$d_{ij} = \sqrt{\sum_{k=1}^n (x_{ij} - x_{ik})^2} \quad (4.25)$$

$$d_{ij} = \sum_{k=1}^n |x_{ik} - x_{jk}| \quad (4.26)$$


Istnieje kilka sposobów modyfikacji algorytmu poprzez zmianę metryki miary odległości. Przykładowo stosuje się metodę ważonych odległości najbliższych sąsiadów, lub wykorzystuje się struktury neuronowe AANG.

4.2.3 Maszyna wektorów nośnych - SVM

SVM - *Support Vector Machine* jest nadzorowaną metodą stosowaną zarówno dla klasyfikacji, jak i wyznaczania regresji. Swoje źródła ma w statystycznej metodzie zaproponowanej przez Vapnika w 1995 r. SVM generuje mapowanie wejść-wyjść na podstawie zbioru treningowego z przypisanym wyjściem. SVM można określić jako prostą geometryczną interpretację zależności rozgraniczających populacje w kontekście opisujących je parametrów. Ostateczny wynik zależy od funkcji strat L , wybranej funkcji jądra i wymaganego stopnia dopasowania klasyfikatora. Najprostszy klasyfikator SVM przedstawiono na rys. 4.15[53, 106].

Liniowe klasyfikatory sprawdzają się tylko w sytuacjach, gdy analizowane klasy obiektów są znacząco separowane. W przypadku, gdy wykres scatterplot cech zawiera przypadki nakładania się na siebie, powoduje to konieczność użycia bardziej zaawansowanych technik klasyfikacji 4.14.

Algorytm SVM stosowany jest w przypadku sygnałów dźwiękowych i obrazów, gdzie duże zbiory parametrów (cech) są stosunkowo mocno skorelowane względem siebie.



Rysunek 4.15: Ilustracja klasyfikatora SVM i miar go opisujących [129]

4.2.4 Sieci neuronowe i głębokie sieci neuronowe

Pierwsze opracowania komputerowego systemu klasyfikacji opartego na działaniu ludzkiego neuronu powstały w latach 50. ubiegłego wieku [113]. Perceptron był jednowarstwowym systemem rozpoznawania małej liczby wzorców. Dalsze prace prowadzone w latach 60. przez Minkiego i Papert [89] wykazały znaczne ograniczenia ówczesnych systemów wykorzystujących perceptron – wynikało to głównie z ograniczeń technologicznych. W latach 80. sieci neuronowe zostały rozbudowane o dodatkowe warstwy, jednak ówczesne komputery nie były w stanie osiągnąć pełnych możliwości tego typu algorytmów. Obecne dziesięciolecie, powiązane zarówno z rozwojem dysków twardych, jak i zaawansowanych procesorów i procesorów graficznych są w stanie wykazać pełne możliwości sieci neuronowych.

Sieć neuronowa jest dwustanowym modelem regresji lub klasyfikacji. Typowo przedstawiana jest za pomocą sieciowego diagramu przedstawionego na rys. 4.16. W przypadku modelu regresyjnego $K = 1$ (klasa) sieć posiada jedno wyjście Y_1 . Przy klasyfikacji K -parametrów wynikiem systemu decyzyjnego jest wektor Y_k , $k = 1, 2, \dots, K$, przy czym K przyjmuje wartość 0-1.[50].

Wartości Z_m , wyznaczane są na podstawie liniowej kombinacji wektora wejściowego. Wektor docelowy Y_k modelowany jest jako funkcja liniowej kombinacji wartości Z_m :

$$\begin{aligned} Z_m &= \sigma(\alpha_{0m} + \alpha_m^T X), \quad m = 1, 2, \dots, M, \\ T_k &= \beta_{0k} + \beta_k^T Z, \quad k = 1, 2, \dots, K, \\ f_k(x) &= g_k(T), \quad k = 1, 2, \dots, K. \end{aligned} \tag{4.27}$$


gdzie:

$$Z = (Z_1, Z_2, \dots, Z_M,$$

$$T = (T_1, T_2, \dots, T_K,$$

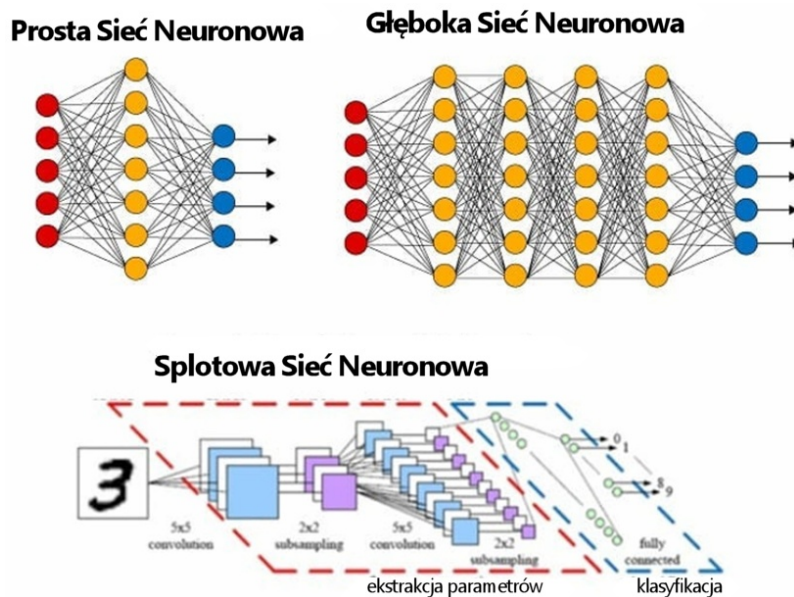
Parametr σ oznacza funkcję aktywacji i typowo stosowaną funkcją jest *sigmoid* ($\sigma(v) = \frac{1}{1+e^{-v}}$). Parametr β oznacza bias (tj. przesunięcie funkcji). Funkcja wyjścia $g_k(T)$ pozwala na transformację wektora wyjściowego T , określana jest mianem funkcji *softmax* i wyznaczana jest za pomocą wzoru:

$$g_k(T) = \frac{e^{T_k}}{\sum_{l=1}^K e^{T_l}} \tag{4.28}$$



Rysunek 4.16: Prosty schemat sieci neuronowej z p wejściami X , jedną warstwą oraz K -elementowym wektorem wyjściowym [141]

Obecne możliwości sprzętowe pozwalają na rozbudowanie struktury sieci. Dodatkowo możliwe jest podanie danych na wejście sieci, które nie są sparametryzowane, stosując do tego celu splotowe sieci neuronowe bazujące na graficznych reprezentacjach sygnału (rys. 4.17).



Rysunek 4.17: Porównanie dostępnych rodzajów sieci neuronowych – prosta sieć, z jedną warstwą ukrytą, głęboka sieć zawierająca typowo kilka do kilkunastu warstw ukrytych oraz sieci splotowe stosowane typowo w systemach rozpoznawania obrazu [141]

Modele sieci neuronowych opisywane są za pomocą nieznanymi parametrów zwyczajowo zwanych wagami. Zadaniem procesu uczenia jest znalezienie takich war-

tości wag, aby przygotowany model odpowiadał przygotowanym danym treningowym:

$$\begin{aligned} & \{\alpha_{0m}, \alpha_m; m = 1, 2, \dots, M\} \quad M(p + 1) \text{ wagi} \\ & \{\beta_{0k}, \beta_k; m = 1, 2, \dots, K\} \quad K(M + 1) \text{ wagi} \end{aligned} \quad (4.29)$$

W przypadku zadania regresyjnego, do badania dopasowania wag, stosuje się funkcję błędu. Do jej wyznaczania najczęściej wykorzystuje się odległość średniokwadratową między odpowiedzią oczekiwaną a odpowiedzią uzyskaną przez sieć 4.30. Zaś dla systemów klasyfikacyjnych stosuje się np. kwadrat odchylenia 4.31.

$$R(\theta) = \sum_{k=1}^K \sum_{i=1}^N (y_{ik} - f_k(x_i))^2 \quad (4.30)$$

$$R(\theta) = - \sum_{k=1}^K \sum_{i=1}^N (y_{ik} \log f_k(x_i)). \quad (4.31)$$

Przy konstruowaniu sieci neuronowych obecne możliwości sprzętowe sugerują budowanie głębokie - z szeregiem warstw ukrytych. Jednak należy brać pod uwagę fakt, że mała liczba warstw może uniemożliwić wykrycie nieliniowości w danych, z kolei zbyt duża liczba warstw może powodować wyliczanie zerowych wag. Typowo, zalecana liczba warstw ukrytych mieści się w przedziale 5-100. Stosowanie różnych wymiarów warstw, może dodatkowo wprowadzać pewną hierarchiczność cech obiektu [76], co z kolei może być przydatne w pogłębionej analizie otrzymanych wyników, ale może też wprowadzać zniekształcenia w obrazie klasyfikacji.

4.3 Przetwarzanie wstępne i analiza danych

Ważnym etapem przygotowawczym jest wstępna obróbka danych. Warto pamiętać o tym, iż surowe (ang. *raw data*) dane zawierają często błędy, szумы i zniekształcenia wynikające np. ze sposobu rejestracji danych. Może też wystąpić problem niepełnych danych (przykładowo system zarządzania utracił łączność z detektorami). Wprowadzenie do klasyfikatorów zniekształconych lub niepełnych danych może doprowadzić do uzyskiwania błędnych wyników czy też problemów ze stabilnością odpowiedzi.

Jedną z metod wykrycia błędu jest analiza zmienności parametru w obrębie klasy. Gdy wartość wariancji jest wysoka, problem dotyczy braku precyzji danej miary, zaś w przypadku, gdy wartość obiektu znacząco odbiega od wartości średniej dla danej klasy może to oznaczać błąd w danych. Systemy klasyfikacyjne muszą generalizować dostarczony zbiór treningowy - na podstawie wycinka obiektów - muszą nauczyć się rozpoznawać ich różne modyfikacje. Stąd też często w grupach treningowych występują obiekty poddane sztucznemu zaszumieniu czy zniekształceniom. Poza zwiększaniem biblioteki dźwiękowej, poprawia to odporność systemu na przetrenowanie. Etap przygotowywania zbioru danych treningowych i testowych nazywa się przetwarzaniem wstępnym (*pre-processing*) i odgrywa ważną rolę w systemach

klasyfikacyjnych.

Proces parametryzacji sygnałów może dostarczyć szczegółowy opis obiektu za pomocą cech. W przypadku analizy dźwięku parametry, wyznaczone zarówno w dziedzinie czasu, jak i częstotliwości (również w dziedzinie czasowo-częstotliwościowej), przedstawiane są za pomocą zróżnicowanych wartości liczbowych.

Dostępne metody przekształcania danych wejściowych mają na celu minimalizację różnic w reprezentacji danych. Do tego typu przekształceń można zaliczyć pierwiastek kwadratowy, odwrotność wartości, logarytm czy podnoszenie do potęgi wartości parametru. Kombinację tych równań określane są normalizacją [49, 131].

4.3.1 Normalizacja

Ważnym etapem jest proces transformacji danych. W procesie *Data Mining*, większość operacji opiera się na wyznaczeniu odległości między poszczególnymi klasami. Wyznaczając parametry z różnych dziedzin opisu obiektu, uzyskuje się różne zakresy wartości co wymaga ich późniejszego ujednoczenia [52, 1, 131].

Proces transformacji zmiennych określany jest mianem normalizacji, postać ogólną przedstawiono we wzorze 4.32. Najprościej ujmując, normalizacja służy dopasowaniu rozmiaru i relatywnej wagi poszczególnych parametrów. Uzyskiwane jest to między innymi poprzez przeskalowanie danych. W przypadku porównywania kilku lub kilkunastu parametrów występujących w różnych skalach zmniejsza to różnice w rozrzucie wartości. Proces ten jest ważny szczególnie w przypadku sieci neuronowych, gdzie znaczne różnice w reprezentacji cyfrowej mogą zakłócić system przedzielania wag poszczególnym neuronom [81].

$$z_{ij} = \left(\frac{x_{ij} - a}{b} \right)^p \quad (4.32)$$

gdzie:

z_{ij} - zmienna po transformacji analizowanego sygnału w czasie k ,

z_{ij} - znormalizowana wartość x

a - parametr (odniesienia)

b - parametr

p - mnożnik

Istnieje kilka typowych metod normalizacji: klasyczna normalizacja (wzór 4.32) transformuje zbiór danych do postaci średniej arytmetycznej wynoszącej zero i odchylenia standardowego równego 1. Dodatkowo wyróżnić można standaryzację pozytywną. Najczęściej spotykanym zakresem standaryzacji jest transformacja do zakresu

$\langle -4,4 \rangle$ i $\langle -1,1 \rangle$. Wartość średnia wynosi 0 4.34.

$$z_{ij} = \frac{x_{ij} - \bar{x}_j}{\sigma_j} \quad (4.33)$$

$$z_{ij} = \frac{x_{ij} - M(x_j)}{MOB(x_j)} \quad (4.34)$$

Unitaryzacja polega na przekształceniu zmiennych do postaci o zakresie zmienności, definiowana poprzez różnice ich wartości maksymalnej i minimalnej w ujęciu klasycznym lub max z medianowym odchyleniem bezwzględnym dla miar pozycyjnych. Przekształcenia ilorazowe polegają na odniesieniu zmiennych do pewnej stałej.

Z-score

Metoda ta jest jedną z form standaryzacji danych. Jest związkiem między różnicą obiektu od średniej w obrębie klasy a odchyleniem kwadratowym klasy (wzór 4.35). Metoda ta jest często stosowana przy maszynowym rozpoznawaniu dźwięku.

$$z' = \frac{x_i - \bar{F}}{\sigma_F} \quad (4.35)$$

Gdzie:

\bar{F} to wartość średnia dla danej cechy,

σ_F to odchylenie standardowe dla danej cechy.

$$z' = \frac{x_i}{\sigma_F} \quad (4.36)$$

$$z' = \left(\frac{x_i}{\sigma_F} \right)^2 \quad (4.37)$$

Min-max

Metoda min-max ma swoje korzenie w algebrze liniowej i jest podejściem wektorowym, powiązaniem z długością wektora i odległości euklidesowej. Długość wektora jest pierwiastkiem z kwadratów jego składowych. Normalizację dokonuje się poprzez podzielenie elementów wektora przez jego długość. Zakres wartości przy ocenie poszczególnych przedstawicieli analizowanej klasy zawiera się w przedziale między $\langle 0 - 1 \rangle$.

$$z' = \frac{(x_i - \min)}{\max - \min} * (\max' - \min') + \min' \quad (4.38)$$

Gdzie:

\max i \min to wartości maksymalne i minimalne dla danej cechy,

\max' i \min' to nowe przedziały przeskalowanego zbioru danych.

Należy pamiętać, iż większość przekształceń normalizacyjnych doprowadza do

uzyskania wartości średnich dla zbioru równych 0 i odchylenia standardowego równego 1.

4.3.2 Miary bliskości, zgodności, rozrzutu danych

Miary podobieństwa obiektów zostały częściowo omówione w trakcie omawiania klasyfikatorów. Poza przybliżoną odległością euklidesową i miejską, można wymienić odległość Czebyszewa, potęgową czy metrykę Minkowskiego.

Do miar bliskości obiektów można zaliczyć współczynniki zbieżności Cramera, korelacji rang czy korelacji liniowej Pearsona. Miary te odgrywają kluczową rolę w fazie minimalizacji wymiarowości wektora cech.

Istnieje kilka metod prezentowania odległości między obserwacjami. Wizualizacja i ciągła analiza punktów granicznych zasobów danych poprawia kontrolowanie błędów i zniekształceń w bazie, co może rzutować na kontrolę stabilności systemu klasyfikacyjnego [131].


Do graficznych metod przedstawiania obserwacji (danych) można zaliczyć histogramy, wykresy rozrzutu (2D i 3D) oraz wykresy pudełkowe. Z numerycznych metod warto wymienić pomiary rozstępu międzykwartyłowego. Część systemów decyzyjnych ze względu na istnienie ekstremów w danych stosuje wnioskowanie w oparciu o kwartył danych pomiarowych.

Redukcja nadmiarowości wektora cech zachodzi w początkowej fazie klasyfikacji populacji, gdy wektory cech są zwykle rozbudowane. Obliczenia są więc czasochłonne, zarówno na etapie ekstrakcji cech, jak i w późniejszej fazie automatycznej klasyfikacji (np. każda cecha odpowiada za liczbę neuronów w warstwie pierwszej sieci neuronowej, co jednocześnie przekłada się na liczbę warstw ukrytych). Ważnym etapem jest więc operacja minimalizacji długości wektora cech, nazywana również dostrajaniem. Istnieje kilka metod redukcji nadmiarowości w wektorze cech (np. PCA, LDA). W celu optymalizacji procesu należy wybrać parametry mające największy wpływ na poprawny wynik klasyfikacji. Przy selekcji parametrów należy kierować się odpowiednich proporcji między dokładnością klasyfikatora a czasem obliczeń [108, 51, 144].

Liniowa analiza dyskryminacyjna

Liniowa analiza dyskryminacyjna (ang. *Linear Discriminant Analysis*, LDA) stosowana jest zarówno jako metoda klasyfikacyjna, jak i jedna z metod minimalizacji cech obiektu w procesie wstępnego przetwarzania danych. Obiekty, należące do przestrzeni R^d podlegają podziałowi na dwie hiperpłaszczyzny 4.18 za pomocą równania 4.39, gdzie a_0, a_i, \dots, a_d są to odpowiednio wyznaczonymi wagami:

$$g(x) = \begin{cases} 1 & \text{if } \sum_{i=1}^d a_i x^{(i)} + a_0 > 0 \\ 0 & \text{inne} \end{cases} \quad (4.39)$$



Rysunek 4.18: Podział zbioru próbek na dwie hiperpłaszczyzny zapewniające optymalny wynik klasyfikatora

Statystyka Fishera

Statystyka Fishera, nazywana również Fisherowską dyskryminacją liniową [106, 111, 129] jest miarą separowalności klas w obrębie analizowanego parametru. Im wyższa wartość bezwzględna parametru, tym większa odległość między wartościami różnych klas. Statystyka może być przeprowadzana dla liczby klas większej niż 2 [53, 99].

$$V = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{s_x^2}{n_x} + \frac{s_y^2}{n_y}}} \quad (4.40)$$

Gdzie:

V - współczynnik korelacji Behrensa-Fishera

n_x, n_y - liczebność klas X, Y ,

\bar{X}, \bar{Y} - wartości średnie dla parametru X, Y ,

s_x^2, s_y^2 - estyator wariancji parametru.

Korelacja Pearsona

Za pomocą liniowej korelacji Pearsona można wykryć liniową zależność między danymi. W zależności od uzyskanego wyniku r można stwierdzić istnienie korelacji dodatniej, ujemnej lub brak korelacji. Wartość siły korelacji można wyznaczyć na

podstawie wartości bezwzględnej r . Przyporządkowanie odpowiednich wartości znajduje się w tabeli 4.3.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{X})^2 \sum_{i=1}^n (y_i - \bar{Y})^2}} = \frac{cov(x, y)}{\sigma(x)\sigma(y)} \quad (4.41)$$

Gdzie:

r - współczynnik korelacji Pearsona,


x_i, y_i - parametr i -ty ze zbioru X, Y ,

\bar{X}, \bar{Y} - poszczególne obserwacje, wyniki z próby

Tabela 4.3: Wartości siły korelacji w zależności od uzyskanego współczynnika

Lp.	Wartość $ r $	Siła korelacji
1	<0,2	Brak związku liniowego
2	0,2-0,4	Słaba zależność
3	0,4-0,7	Umiarkowana zależność
4	0,7-0,9	Dość silna zależność
5	>0,9	Bardzo silna zależność

Wyniki przedstawia się typowo na wykresach rozrzutu (rys. 4.19). Kierunek i poziom skupienia punktów pomiarowych jest odniesieniem do wartości i kierunku parametru r .



Rysunek 4.19: Wykresy rozrzutu z przykładowymi wartościami i kierunkami korelacji liniowej [91]

4.4 Ocena skuteczności systemów automatycznej klasyfikacji

W kontekście systemów informatycznych istnieje szereg miar oceny skuteczności działania. W zależności od obszaru zastosowania systemu, dobór miar oceny i ich wartości progowe mogą być inne (np. biometria, systemy bezpieczeństwa czy systemy, w których wynik klasyfikacji nie będzie tak istotny).

4.4.1 Wskaźniki oceny skuteczności

W przypadku klasyfikatorów najczęściej stosowanymi miarami są: TP i TN będące oceną zadziałania systemu. *prawdziwie pozytywna* (ang. *True positive*) oznacza, iż system poprawnie sklasyfikował dany obiekt. W przeciwnym przypadku zdarzenie zostaje zliczone jako *falszywie negatywne* (ang. *false negative*) i oznacza błędne zadziałanie systemu. Wartość *falszywie pozytywna* (ang. *false positive*) oznacza niewłaściwe zaklasyfikowanie obiektu do danej grupy, *prawdziwie negatywne* (ang. *True negative*) zaś poprawne odrzucenie obiektu z danej grupy [17, 106]. Zależności te przedstawić można za pomocą macierzy pomyłek (ang. *confusion matrix*).

Do oceny systemów klasyfikacyjnych stosowane są również tablice pomyłek (ang. *confusion matrix*), przedstawiające wyniki TP , TN , FP i FN w postaci macierzowej (tab. 4.4. W przygotowywaniu wyników klasyfikacji dla większej liczby klas, tablice pomyłek zawierają podsumowanie wszystkich odpowiedzi klasyfikatora.

Tabela 4.4: Tablica pomyłek stosowana przy ocenie systemów klasyfikacyjnych w kontekście rozróżniania dwóch klas

		Klasa rzeczywista	
		Pozytywna	Negatywna
Klasa predykowana	Pozytywna	prawdziwie pozytywna (TP)	falszywie pozytywna (FP)
	Negatywna	falszywie negatywna (FN)	prawdziwie negatywna (TN)

W miarami TP , TN , FP i FN wiążą się również miary pozwalające na ogólną ocenę skuteczności systemu: precyzja (PPV , ang. *Precision, Positive Predictive Value*) przedstawia poprawność predykcji systemu za pomocą stosunku poprawnie rozpoznanych zdarzeń do sumy wszystkich wykrytych przez system zdarzeń 4.42. Czulość systemu (TPR , ang. *True Positive Rate*) wyznaczana jest na podstawie wzoru 4.43. Trzecia miara, F – *score* jest ważoną średnią harmoniczną precyzji i czulości systemu i wyznacza się ją na podstawie wzoru 4.44.

$$PPV = \frac{TP}{TP + FP} \quad (4.42)$$

$$TPR = \frac{TP}{TP + FN} \quad (4.43)$$

$$F = \frac{2 \cdot p \cdot r}{(p + r)} \quad (4.44)$$

Poziom błęd (ang. *error rate*, *ERR*) wyznaczany jest na podstawie stosunku błędnie podjętych decyzji do wszystkich decyzji podjętych przez system. Im mniejsza wartość *ERR*, tym większa jest sprawność systemu.

$$ERR = \frac{FP + FN}{TP + TN + FN + FP} = \frac{FP + FN}{P + N} \quad (4.45)$$

Jakość klasyfikacji (ang. *Accuracy*, *ACC*) wyznaczana jest na podstawie wszystkich pozytywnych predykcji podzielona przez liczbę wszystkich obiektów z bazy. Im większa wartość *ACC*, tym lepsza jakość klasyfikatora. Jej wartość może być wyznaczona również z wartości *ERR* (wzór 4.46).

$$ACC = \frac{TP + TN}{TP + TN + FN + FP} = \frac{TP + TN}{P + N} \quad (4.46)$$

W przypadku oceny skuteczności urządzeń detekcji pojazdów GDDKiA w swoich dokumentach [35] proponuje dodatkową miarę oceny skuteczności systemu wyznaczaną za pomocą wzoru 4.47:

$$d = \frac{(N - \epsilon_m - \epsilon_f)}{N} \quad (4.47)$$

gdzie:

N - rzeczywista liczba pojazdów w miejscu detekcji,

ϵ_m - liczba pominiętych pojazdów,

ϵ_f - liczba fałszywie zliczonych pojazdów.

Rozdział 5

Automatyczna klasyfikacja ruchu drogowego

Niniejszy rozdział zawiera opis projektowanego klasyfikatora zdarzeń w ruchu drogowym, jak również warunków związanych ze stanem hydrologicznym jezdni. Na podstawie przeprowadzonych badań i analiz określono wymagania techniczne dotyczące akwizycji danych, następnie opisano proces przygotowania danych do analizy, ekstrakcję wybranych parametrów oraz klasyfikację wybranych problemów związanych z ruchem drogowym.

Zaproponowana funkcjonalność akustycznej analizy ruchu drogowego obejmuje:

1. Detekcję obecności pojazdu,
2. Zliczanie pojazdów,
3. Statystyki ruchu dla zadanych interwałów,
4. Klasyfikację stanu nawierzchni,
5. Klasyfikację trzech typów pojazdów.

W rejestracji danych dynamicznych związanych z ruchem drogowym parametrami wyznaczonymi przez proponowany analizator foniczny są: liczba pojazdów w przedziale czasu obserwacji, średnie natężenie na minutę, średnia prędkość w przedziale obserwacji oraz odległość między pojazdami wyznaczona w jednostce czasu [s]. W trakcie przeprowadzonych pomiarów wzięto pod uwagę fakt, że typową reakcją kierowców na urządzenie pomiarowe przy drodze jest zmniejszanie prędkości pojazdu. Im bardziej jest widoczne urządzenie pomiarowe (przypominające typowe radary stosowane jako urządzenia dyscyplinujące kierowców), tym następuje większe zaburzenie w rzeczywistym ruchu pojazdów. W trakcie rejestracji okazało się jednak, że obecność mikrofonów nie wzbudzała zainteresowania kierowców, również starano się też ograniczać wielkość kamer, dlatego ten aspekt nie powinien wpływać na prowadzony pomiar.


Nagrania foniczne zostały przetworzone w celu ekstrakowania parametrów opisujących dźwięk poruszającego się pojazdu. Charakter dźwięku analizowany jest nie tylko w kontekście poziomu natężenia ruchu, ale w celu ekstrakcji składowych częstotliwościowych i ich zmian w funkcji czasu. Operacje te zostały użyte do wyznaczenia wektora cech, który umożliwia skuteczną wytrenowanie klasyfikatorów. Ponadto przedstawiono wykorzystanie systemów monitorowania hałasu do szacowania ruchu na drogach. Zastosowano metodologię zwaną inżynierią odwrotną w celu wyodrębnienia przybliżonej wielkości ruchu z poziomu hałasu rejestrowanego w danym obszarze.

5.1 Wymagania techniczne i założenia pracy systemu

Urządzenia telematyki drogowej dopuszczalne do stosowania przy polskich drogach podlegają szeregowi wymagań i certyfikacji. Do technicznych wymagań stawianych urządzeniom RPU (ang. *Remote Processing Unit*) należy odporność obudowy na warunki atmosferyczne i środki chemiczne stosowane przy utrzymaniu dróg (norma IP55 [22]). Urządzenie powinno pracować w temperaturach otoczenia między -30°C do $+40^{\circ}\text{C}$ (temperatura urządzenia w zakresie -40°C do $+60^{\circ}\text{C}$). Pozostałe wymagania to między innymi zapewnienie pracy urządzenia przy braku zasilania i łączności (wewnętrzna bateria podtrzymująca i dysk pozwalający na buforowanie danych przez min 24h). Standardem połączeń urządzeń w ITS jest złącze RS232 i co raz częściej Ethernet lub łączność bezprzewodowa. Ze względu na bezpieczeństwo – ważnym zadaniem urządzenia jest autodiagnostyka i sprawna reakcja na błędne działanie urządzenia. Wymagania te zostały szerzej opisane w dokumentacji GDD-KiA pt.: Wymagania systemów telematyki drogowej [122]. W ramach pracy, sprawdzono funkcjonalność akustycznej detekcji ruchu drogowego pod kątem konstrukcji i wdrożenia urządzenia do powszechnego użytku.

Ogólne działanie eksperymentów, przedstawiono na rys. 5.1. Z zebranych próbek dźwiękowych stworzono bazę danych wraz z meta opisem pochodzącym z danych wizyjnych. Kolejne etapy związane z parametryzacją próbek i analizą statystyczną

omówiono w kolejnych rozdziałach.



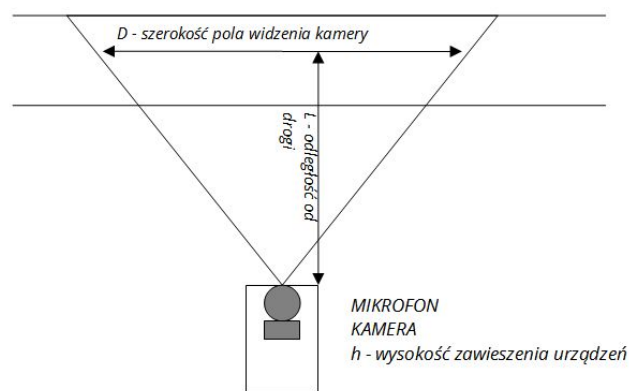
Rysunek 5.1: Uproszczony diagram działania klasyfikacji zdarzeń w ruchu drogowym

5.2 Dźwiękowa baza danych drogowych

W ramach pracy zrealizowano serie wideo-fonicznych nagrań przy trójmiej-
skich drogach. Pozwoliło to na uzyskanie danych odniesienia wnioskowanych na
podstawie obrazu z kamery. W sieci dostępnych jest kilka baz dźwiękowych jed-
nak nastawione są one bardziej na rozpoznawanie scenerii, a nie pojedynczych prze-
jazdów [140, 60]. Dodatkowo nagrania nie posiadały odpowiedniej dokumentacji -
informacji o konfiguracji pomiarowej (odległości od jezdni, typ i rodzaj mikrofonu)
czy też danych odniesienia, stąd wynikała potrzeba rejestracji próbek.

5.2.1 Akwizycja danych

Nagrania przeprowadzono z wykorzystaniem rejestratora Zoom H6 i równocze-
snej rejestracji z mikrofonu typu shotgun (Zoom SGH-6) oraz wszechkierunkowego
mikrofonu pojemnościowego Behringer EMC8000. Materiał nagrywano w próbkowa-
niem 96 kHz/24. Konfiguracja pomiarowa przedstawiona jest na rys 5.2. Ponadto
rejestrowano równocześnie sygnał wideo, który stanowił możliwość sprawdzenia pra-
widłości detekcji zdarzeń w sygnale fonicznym (i stanowił tzw. *ground truth*).



Rysunek 5.2: Schemat pomiarowy

Wybrano kilka miejsc pomiarowych, które w miarę możliwości, pozwalały na

zebranie izolowanych przejazdów (Punkt A - Kazimierz, ulica Rumska), jak i rejestrację przejazdów kolumny pojazdów (Punkt B – Gdańsk, aleja Armii Krajowej, rys.5.3). Rejestracji dokonywano w różnych porach roku i dla zróżnicowanych warunków pogodowych. Dla kompletności danych w trakcie pomiarów rejestrowano temperaturę i wilgotność na poziomie gruntu i na wysokości pomiaru – 1,5m.

Adnotacja nagrań dokonywana była na podstawie zsynchronizowanego nagrania wideofonicznego. Dodatkowo eksportowano fragmenty audio, rozbudowując w ten sposób bazę dźwiękową o dodatkową grupę danych walidacyjnych. Nagrania sygnałów zostały przetworzone w celu wyodrębnienia parametrów dźwięku ruchu.

Odległość akustycznego detektora pojazdów od źródła uzależniona jest rozkładem pasów i charakterem otoczenia. Uwzględniając normy pomiaru hałasu, przyjęto minimalne odległości pomiarowe od środka jezdni. W akustyce, należy kierować się odległością większą niż mierzone długości fal, co w przypadku ruchu drogowego oznacza pasmo 125 Hz do 4 kHz.



Rysunek 5.3: Akwizycja danych pomiarowych, rejestrator z kamerą wideo (po lewej) oraz radarowy rejestrator ruchu dzięki uprzejmości GDDKiA (po prawej)

Metody ekstrapolacji banku próbek

Ze względu na ograniczoną liczbę próbek treningowych zastosowano operację powiększenia bazy danych. W trakcie realizacji nagrań rejestrowano równocześnie co najmniej dwa sygnały foniczne z zastosowaniem różnych przetworników. Inną zastosowaną metodą zwiększenia danych treningowych i testowych było wprowadzanie zmian w postaci szumów i zniekształceń do wcześniej przygotowanych nagrań jeszcze przed procesem parametryzacji (ok. 20% materiału) oraz modyfikacja wyników parametryzacji (skrypt. `OverScale.m`).

5.2.2 Przetwarzania danych wejściowych

W fazie przetwarzania danych korzystano początkowo ze specjalistycznego oprogramowania Matlab z pakietem *signal processing* i pakietem *MIR toolbox*. Jednak dalsze badania prowadzono już z wykorzystaniem oprogramowania GNU Octave należącego do grupy Open Source. W trakcie obliczeń korzystano z pakietów z

projektu Forge [100] i innych współpracujących projektów. Oprogramowanie GNU Octave można rozbudowywać o własne biblioteki na podstawie licencji *GNU General Public Licence* (GPL) publikowanej przez *Free Software Foundation*. Oprogramowanie jest do pewnego stopnia kompatybilne z oprogramowaniem Matlab. Nowszą wersję Matlab stosują jednak inne systemy zapisu struktur danych i środowiska, co utrudnia równoczesną pracę w obu środowiskach. Poniżej omówiono kilka głównych pakietów, z których korzystano w ramach pracy i które były modyfikowane przez autorkę rozprawy w trakcie prowadzonych badań.

Edycję próbek testowych, zawierających indywidualne przejazdy, przeprowadzono za pomocą oprogramowania Audacity i Cubase LE.

Signal

Pakiet SIGNAL zawiera podstawowe funkcje przetwarzania sygnałów, włączając to samo odczytywanie i zapis plików wave. Pozwala na tworzenie filtrów FIR, IIR, przekształcenia Fouriera i podstawową analizę spektralną sygnału. Umożliwia również przepróbkowanie (ang. *resampling*) i zmianę częstotliwości zgromadzonych nagrań sygnału fonicznego, pozwalając na sprawdzenie skuteczności systemów przy słabszych parametrach rejestracji niż nagrania treningowe [103].

Speech

Pakiet SPEECH zawiera skrypty obliczające parametry charakterystyczne dla sygnału mowy oraz funkcje buforowania ramek sygnału. Używany był głównie w procesie badania aktywności w sygnale za pomocą funkcji *peek2peek* (ang. *peek-to-peek*, wartość międzyszczytowa), *peek2rms* (ang. *peek-to-RMS* wartość szczytowa do wartości skutecznej), *RMS* (*Root Mean Square*, wartość skuteczna) i *rssq* (ang. *root-sum-of-squares*, RQSS). Dodatkowo wykorzystywano pakiety obliczające funkcje badające korelacje w sygnale (korelacje, kowariancja, korelacja skrośna). Pakiet umożliwia tworzenie filtrów FIR i IIR, oraz wyznaczenie transformat sygnału fonicznego [104].

LTFAT

Pakiet LTFAT (Large Time/Frequency Analysis Toolbox) zawiera bardzo duży zestaw funkcji służących analizie czasowo-częstotliwościowej oraz syntezie dźwięku. Umożliwia przeprowadzenie transformacji Gabora i falkowej. Pakiet wyposażono w zestaw filtrów uwzględniających właściwości ludzkiego słyszenia. Pakiet ten działa również w środowisku Matlab[101].

NaN

Pakiet NaN zawiera funkcje statystyczne umożliwiające pracę z niekompletnymi danymi, rozbudowane operacje statystyczne, jak i typowe zabiegi stosowane przy

przetwarzaniu wstępnym sygnału. Są to m.in. funkcje: *kurtosis*, *mcd*, normalizacja *zscore* i podstawowe algorytmy klasyfikacyjne: LDA, klasteryzacja czy wizualizację za pomocą funkcji *scatter plot* [102].


MIRToolbox

Pakiet MIRToolbox został opracowany na potrzeby systemów MIR. Jest wykorzystywany w środowisku Matlab. Zawiera głównie funkcje dotyczące analizy barwy i rytmu sygnału oraz funkcje statystyczne. Umożliwia analizę z podejścia *big-frame* i *bag-of-frames* (analiza całego pliku lub uśredniona wartość z kilku ramek).


Dodatkowo, pakiet wyposażono w operacje klasteryzacji i tworzenie macierzy podobieństw. Ze względu na strukturę skryptów i ich współzależność, czas przetwarzania danych przez pakiet jest stosunkowo wysoki. Dla przykładu użycie dwóch funkcji bazujących na widmie sygnału wymaga dwukrotnego wyznaczenia widma. Czas obliczeń rośnie wraz z długością łańcucha obliczeń dla parametru i liczby deskryptorów [69].

5.3 Realizacja algorytmów akustycznego monitoringu drogowego

Podstawowym zadaniem opracowanego systemu jest zbieranie informacji dotyczącej natężenia ruchu drogowego na podstawie wykrywania zmian w sygnale fonicznym zarejestrowanym w pobliżu drogi. Schemat działania systemu pokazano na rysunku 5.4. W zależności od analizowanego parametru, tj. poziomu szumów, RMS sygnału lub poziomu chropowatości dźwięku wybierany jest próg wykrywania obecności pojazdów. Przyjęta w badaniach pilotażowych [84] wartość progowa została wyznaczona eksperymentalnie i zależała od natężenia ruchu na godzinę i maksymalnego poziomu dźwięku przy uwzględnieniu odległości mikrofonu od drogi. Próg reakcji algorytmu został wyznaczony na podstawie parametrów statystycznych w zbuforowanej ramce analizy (okno analizy ok. 30 s.).



Rysunek 5.4: Uproszczony diagram działania detekcji obecności pojazdów




Rysunek 5.5: Typowy schemat systemu polegający na detekcji aktywności w sygnale

5.4 Detekcja zdarzeń

W przypadku detekcji zdarzeń w sygnałach audio najczęściej stosowaną metodą jest śledzenie zmian poziomu sygnału w czasie. Metoda VAD (ang. *Voice Activity Detection*) jest typowo stosowana w przypadku wykrywania aktywnych ramek mowy (rys. 5.5). Algorytmy te miały na celu zmniejszenie zajętości kanału transmisyjnego, minimalizując transmisję pustych ramek sygnału, bowiem przekroczenie progu detekcji/reakcji powoduje zapisanie próbek dźwiękowych o wyższej aktywności do bufora, który następnie przekazywany jest do klasyfikatora w celu oceny źródła dźwięku. Najprostszym systemem ATM jest algorytm zliczania pojazdów na podstawie zmian w krótkookresowych poziomach hałasu. Skuteczność systemu w głównej mierze zależy od częstotliwości próbkowania sygnału, przyjętego progu detekcji i czasu adaptacji progu.

Algorytm detekcji aktywności w sygnale został przebadany w różnych opcjach z wykorzystaniem kilku miar: *RMS*, *Peek to Peek* (P2P), *Peek to RMS* (P2RMS), *Root Sum of Squares* (RSSQ) i *Zero Crossing Ratio* (ZCR). Parametr służący do aktywacji detekcji i analizy zawartości sygnału musiał charakteryzować się znaczną szybkością reakcji na zmiany w sygnale, zachowując przy tym odporność na zaszumienie w sygnale. Dodatkowym wymaganiem była złożoność obliczeniowa. Ze względu na charakter strumienia sygnału ruchu drogowego nie uwzględniono miary SNR (ang. *Signal to Noise Ratio*). Dotyczy to głównie pojazdów poruszających się w kolumnach.

Na rysunku 5.6 przedstawiono wyniki przebiegu czasowego sygnału oraz odpowiadające wartości wymienionych parametrów. Analizę przeprowadzono dla sygnału długości 1 minuty. Zastosowana ramka analizy wynosiła 125 ms z 50% zakładkowaniem.




Rysunek 5.6: Wyniki śledzenia aktywności w sygnale dla kilku parametrów

5.4.1 Adaptacja progu detekcji


Ze względu na duże wahania natężenia ruchu w ciągu doby przyjęcie stałego poziomu reakcji może skutkować dużą liczbą fałszywych odczytów w godzinach szczytu oraz niską skutecznością detekcji dla godzin nocnych, gdy natężenie ruchu spada często wielokrotnie (pięciokrotnie) w stosunku do pór dziennych 5.7. Poziom dźwięku rejestrowany w ciągu dnia jest różny w zależności od natężenia ruchu i aktywności człowieka. Próg detekcji musi być dopasowany do panujących aktualnie warunków akustycznych.

Głównym celem stosowania adaptacji jest zmienność tła akustycznego w ciągu doby, ale i w krótkich okresach czasu. Uwarunkowane jest to pulsacyjnym charakterem ruchu (należy również odnieść to do modelu jazdy za liderem [34]). Zaprezentowana na rys. 5.7 charakterystyka zmian w ciągu doby i tygodnia dla hałasu drogowego jest tego dobrym przykładem. Pominięcie procesu adaptacji progu może skutkować błędnym wykryciem pojazdu lub pominięciami detekcji w zależności od ustalonego progu.



Rysunek 5.7: Tygodniowy rozkład hałasu L_{A1Heq} rejestrowany na jednej z większych ulic Gdańska - Łostowicka.

W przypadku braku adaptacji sygnału program nie reagowałby na kolumny pojazdów, traktując przejazdy kilku obiektów jako jeden, długi przejazd, co przedstawiono na rysunku 5.8. Ze względu na dużą zmienność sygnału w czasie i utrzymujący się wysoki poziom sygnału między przejazdami w kolumnach, adaptacja progu musi przebiegać w krótkich ramkach, uwzględniając wartości maksymalne, minimalne i wariancję w sygnale.



Rysunek 5.8: Wyniki wykrywania dla pojazdów w przypadku braku zastosowania adaptacji progu reakcji, ramka 500 ms, zakładkowanie 25%

5.4.2 Zliczanie pojazdów

Zarejestrowane sesje zostały podzielone na pliki foniczne o długości 5 minut. Poszczególne fragmenty zostały sprawdzona ręcznie z zarejestrowanym sygnałem wideo w celu wyeliminowania zakłóceń w danych pomiarowych. Następnie przeprowadzono obliczenia za pomocą zaproponowanej metody progu adaptacyjnego. Eksperymentalnie dobrano próg bazujący na wartościach średnich sygnału w buforze, wartości maksymalnej, mediany oraz wariancji. Dodatkowo, zastosowano badanie płaskości i skrośności wartości RMS. Finalnie, badając punkt położenia wartości maksymalnej w ramce - w zależności od tempa wzrostu lub wartości RMS - zwiększano lub zmniejszano wartość progu o mnożnik tempa zmian. Wzór na zastosowaną adaptację przedstawiono w formie równania 5.1:


$$TsL = \overline{TsV} + (max(TsV) - Me(TsV)) \cdot s^2(TsV) \cdot (Diff/Tem) \quad (5.1)$$

gdzie:

TsL - poziom progu detekcji,

\overline{TsV} - wartość średnia wektora (zawartość bufora adaptacji),

$max(TsV)$ - wartość maksymalna w wektorze,



Rysunek 5.9: Wyniki wykrywania dla pojazdów w przypadku braku zastosowania adaptacji progu reakcji, ramka 500 ms, zakładkowanie 25%

$Me(TsV)$ - mediana w wektorze,


s^2 - wariancja w wektorze,

$Diff/Tem$ - parametr stromości zbocza wyznaczany z położenia wartości maksymalnej w wektorze.


Sposób dobierania wartości $Diff/Tem$ przedstawiono na rysunku 5.9, gdzie $F-Trj$ to stopień nachylenia zbocza.

W algorytmie zastosowano adaptację progu detekcji. Na rys. 5.10 przedstawiono metodę szybkiej adaptacji progu pozwalającej na zliczanie pojazdów jadących w kolumnie. Czas adaptacji progu zależy od aktualnego natężenia ruchu i poziomu hałasu otoczenia. Godziny szczytu charakteryzują się dużym zagęszczeniem ruchu i małymi odległościami pomiędzy pojazdami, stąd adaptacja progu musi następować dynamicznie, aby rozróżnić poszczególne pojazdy. Inaczej grupa pojazdów może być potraktowana jako np. jeden pojazd ciężarowy (rys. 5.10).

W porach nocnych różnice między szumem (poziomym tłem) a energią wynikającą z przejazdu pojedynczych pojazdów charakteryzują się większymi wartościami.



Rysunek 5.10: Zliczanie pojazdów na podstawie generowanego sygnału z zastosowaniem progu detekcji z adaptacją



Rysunek 5.11: Zliczanie pojazdów na podstawie generowanego sygnału z zastosowaniem progu detekcji z adaptacją

Zgodnie ze schematem z rys. 5.8 ramki oznaczone jako "aktywne" są przekazy-

wane do systemu klasyfikacji. Korzystając z pełnych danych szczegółowych, można obliczyć średnią objętość ruchu, odległość pomiędzy pojazdami i inne informacje o ruchu. W tabeli 5.1 przybliżono czas obliczeń dla poszczególnych funkcji śledzenia sygnału w dziedzinie czasu i wymiaru ramki analizy.

Tabela 5.1: Wyniki analizy parametrów detekcji aktywności w sygnale i wyznaczone liczby pojazdów dla okna analizy 5 min. Skuteczność detekcji wyznaczana jest za pomocą wzoru 4.47 (l. pojazdów w analizowanym fragmencie 135, zakładkowanie 50%, adaptacja progu detekcji 2 s)

Parametr	Wymiar okna [ms]	Czas analizy [s]	L. pojazdów	Skuteczność detekcji [%]
<i>RMS</i>	100	14,87	149	90
	125	12,02	131	97
	200	7,68	91	67
	250	6,26	86	64
	500	3,28	82	61
<i>ZCR</i>	100	214,20	137	24/
	125	208,37	165	78
	200	195,07	101	75
	250	193,14	73	54
	500	184,97	33	24
<i>P2P</i>	100	16,76	144	93
	125	13,57	122	90
	200	8,56	87	64
	250	7,00	81	60
	500	3,68	73	52
<i>RSSQ</i>	100	38,30	3	2
	125	14,11	6	4
	200	9,00	18	13
	250	7,35	39	29
	500	3,96	53	39


Czasy aktywacji sygnałów przekazywane są do funkcji `ITSParStat.m` wyznaczającej parametry dotyczące zajętości przekroju drogi w danym punkcie analizy. Stąd kluczowe było nie tylko wprowadzanie znaczących opóźnień spowodowanych wymiarem ramki, jak i zachowanie odpowiedniego poziomu czułości niwelującego zdarzenia typu *FP* i *FN*. Rejestrowane zapisy z detekcji zawierają takie dane jak:

1. ID zdarzenia;
2. `VehDetTime` - czas zdarzenia;
3. `VehEveTime` - czas trwania zdarzenia;
4. `VehDisTime` - odstęp między zdarzeniami (liczony od momentu wykrycia zdarzeń);

-
5. VehDisLTime - przerwa między zdarzeniami (liczony od końca zdarzenia do początku zdarzenia następującego);

Następnie, na ich podstawie dla zadanego przedziału obserwacji wyznaczana jest średnia liczba pojazdów na godzinę, zajętość przekroju drogi, wartości średnie i kwantyle dotyczące miar od 3-5. Dokładnie o miarach w dodatku A. Przestrzenie czasowe między pojazdami przekładają się na Pozom Swobody Ruchu. Przyjmuje się, że 6 s przerwy między zdarzeniami pozwala już na swobodę doboru prędkości w ruchu swobodnym [33].

Dla wybranej metody detekcji pojazdu przebadano skuteczność z wykorzystaniem danych odniesienia z ręcznego pomiaru, wskazań radarowego detektora pojazdu TMS-SA oraz LiDARowego detektora Vitronic. Każda z metod, przybliżonych w rozdziale 2 reprezentuje odmienną technologię działania. Różnią się wymiarem strefy pomiaru, jak i kątem widzenia. Vitronic ustawiany jest na wysokości 0,5-1,5 m. Jego strega pomiaru wynosi ok 50 m i znajduje się w odległości 70-20m od detektora. TMS-SA instalowany jest na wysokościach 2-3m. Jego kąt obserwacji jest mniejszy względem prostej prostopadłej do drogi i charakteryzuje się mniejszą strefą pomiarową. W trakcie pomiarów porównawczych, został ustawiony 20 m przed detektorem optycznym. Najbliżej względem kierunku ruchu najbliższego pasa, ustawiono rejestrator do analizy akustycznej. Ze względu na różne częstotliwości odświeżania urządzeń, czasy detekcji poszczególnych urządzeń mogą się różnić. Na wykresie 5.12 przedstawiono wybrany fragment zsynchronizowanych pomiarów porównawczych.




Rysunek 5.12: Wyniki zliczania trzema. Uzyskane wykrycia w funkcji czasu.

Wyniki uzyskane dla różnych czasów obserwacji przedstawiono na wykresie 5.13 i w tabeli 5.2.

Tabela 5.2: Liczba wyznaczonych pojazdów na podstawie trzech metod - Doppler TMS-SA (koszt ok 6 tys.), LiDAR (koszt ok. 120 000 zł), opracowywana metoda akustyczna oraz dane ze zliczania ręcznego na podstawie strumienia wideo

Minuta badania	Doppler	LiDAR	Akustyczna	Ground truth
5	121	124	125	152
10	216	221	286	271
15	319	332	385	392
20	432	442	482	546
25	523	543	576	667
30	614	642	680	794
35	720	756	809	913
40	839	874	932	1081
45	945	985	1063	1204

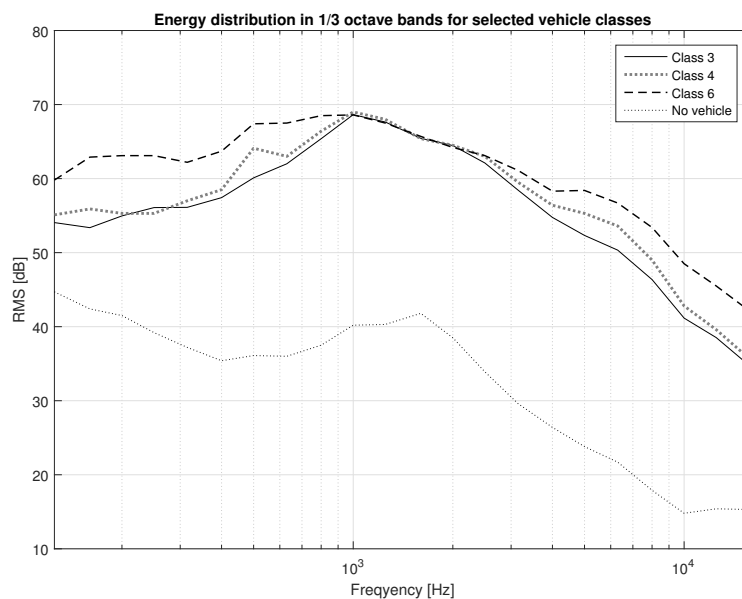


Rysunek 5.13: Wyniki zliczania trzema metodami pomiaru wraz z danymi odniesienia

5.4.3 Detekcja typu pojazdu

W rozdziale drugim omówiono główne parametry pojazdu wpływające na generowany hałas. Różne typy pojazdów charakteryzują się różnymi parametrami geometrycznymi (gabaryty, liczba osi i szerokość opon) jak i technicznymi (typ i moc silnika,) przekłada się to również na ich brzmienie. Na podstawie zarejestrowanych próbek, przygotowano nagrania zawierające izolowane przejazdy sklasyfikowanych wizualnie pojazdów. Wstępne badania polegały na analizie widmowej sygnałów, co pozwoliło na przedstawienie zbiorowych wyników charakteryzujące trzy, najczęściej spotykane typy pojazdów na badanych drogach. Wyniki tych badań przedstawiono w publikacji *Traffic Noise Analysis Applied to Automatic Vehicle Counting and Classification* [84].

Uzyskane wyniki uśredniając dla ok. 100 pomiarów (72% osobowe – klasa 3,



Rysunek 5.14: Różnice między klasami pojazdów w kontekście zawartości widmowej (po lewej), efektem LDA dla dwóch wybranych klas pojazdów z danymi nieprzydzielanymi do żadnej klasy pojazdów, powodującymi nakładanie się w grupach (po prawej).

23% pojazdy małe dostawcze – klasa 4 i 5% zarejestrowanych próbek stanowiły przejazdy pojazdów ciężkich), przy czym, ze względu na charakter rejestracji – sygnał akustyczny, poszczególne pojazdy przydzielano wg. generowanych poziomów hałasu, co nie zawsze pokrywało się z klasyfikacją nadwozi pojazdów z Dz. U. czy klasyfikacji FHWA. Problemy stanowiły pojazdy starsze, generujące znacznie wyższe poziomy hałasu z dodatkowymi modulacjami wynikającymi często z niesprawności pojazdu. Na rysunku 5.14 przedstawiono, w jaki sposób rozkładają się składowe widma dla pojazdów wybranych trzech klas.

Aktywne ramki, zawierające przejazdy pojazdów kierowane są do klasyfikatora typu pojazdu. W pracy wydzielono cztery typy pojazdów – motocykle, pojazdy osobowe, małe dostawcze i pojazdy ciężkie. Na etapie treningu klasyfikatora, przebadano kilka algorytmów uczenia maszynowego omawianych w rozdziale 4.

Klasyfikacji poddano zbiór 302 próbek zawierających izolowane przejazdy (103 pojazdy osobowe, 62 pojazdy dostawcze, 42 pojazdy ciężarowe i 95 motocykli). W środowisku Octave, zebrane próbki poddano zaszumieniu (po 15% z każdej grupy) i tak ekstrapolowany zbiór próbek poddano parametryzacji, wyznaczając wektor 67 użytecznych parametrów (spis parametrów w Dodatku B).

Przetestowano kilka metod klasyfikacji na podstawie zebranego zestawu danych. Próbki dodatkowo poddano zwielokrotnieniu za pomocą modyfikacji wartości parametrów uzyskanych w procesie ekstrakcji. Podzielono je na zbiory treningowe i testowe, dokonując losowego przydziału próbek dla każdej iteracji modelu. Trening wykonywano do czasu uzyskania wartości detekcji powyżej ustalonego progu, jednak

nie dłużej niż 35000 iteracji. Uzyskane wyniki przedstawiono w tabelach 5.3-5 dla naiwnego klasyfikatora Bayesa, 5.6-8 dla liniowej analizy dyskrymacyjnej Fishera, 5.9-11 dla regresji liniowej, 5.12-14 liniowy perceptron i zwykła liniowa analiza dyskryminacyjna w tabeli 5.15-17. Podsumowanie jakości klasyfikacji przedstawiono w tabeli 5.18.

Naiwny klasyfikator Bayesa

Tabela 5.3: Trafność klasyfikacji (ACC) Naiwny klasyfikator Bayesa (liczba parametrów: FV=67, wyniki dla zbioru testowego 40%)

Numer serii treningu	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
1	0,823	0,866	0,905	0,995	0,897
2	0,833	0,901	0,877	0,971	0,896
3	0,861	0,880	0,899	0,990	0,908
4	0,853	0,905	0,913	1,000	0,918
5	0,840	0,891	0,895	1,000	0,906
Średnio dla klasyfikatora	0,842	0,888	0,898	0,991	0,905

Tabela 5.4: Najlepsza uzyskana skuteczność dla klasyfikatora NBC przy analizie typu pojazdu (zbiór treningowy 60%)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	133	0	0	0	0,864	1,000	0,731	0,844
Dostawcze	27	14	11	0	0,886	0,269	0,875	0,412
Ciężarowe	21	2	18	0	0,901	0,439	0,621	0,514
Motocykl	1	0	0	145	0,997	0,993	1,000	0,997
Średnia:					0,912	0,675	0,807	0,692

Tabela 5.5: Najlepsza uzyskana skuteczność dla klasyfikatora NBC przy analizie typu pojazdu (zbiór testowy 40%)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	82	0	0	0	0,821	1,000	0,661	0,796
Dostawcze	18	10	10	0	0,861	0,263	0,769	0,392
Ciężarowe	23	3	21	0	0,838	0,447	0,656	0,532
Motocykl	1	0	1	79	0,990	0,975	1,000	0,988
Średnia:					0,877	0,671	0,772	0,677

Klasyfikator poprawnie rozpoznawał motocykle. Problemy stwarzały pojazdy osobowe które mało precyzyjnie uznawane było zarówno za pojazdy dostawcze jak i ciężarowe.

Liniowa analiza dyskryminacyjna - Fishera

Tabela 5.6: Trafność klasyfikacji (ACC) Liniowa analiza dyskryminacyjna-Fishera(FV=67, 40% zbioru testowego)

Numer serii treningu	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
1	0,878	0,882	0,977	1,000	0,934
2	0,902	0,910	0,987	0,987	0,946
3	0,878	0,900	0,951	0,995	0,931
4	0,899	0,929	0,970	0,996	0,948
5	0,915	0,922	0,978	0,996	0,953
Średnio dla klasyfikatora	0,894	0,908	0,973	0,995	0,943

Tabela 5.7: Najlepsza uzyskana skuteczność dla klasyfikatora FLDA przy analizie typu pojazdu (zbiór treningowy 60%)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	127	6	0	0	0,965	0,955	0,948	0,951
Dostawcze	7	43	0	0	0,965	0,860	0,878	0,869
Ciężarowe	0	0	49	0	1,000	1,000	1,000	1,000
Motocykl	0	0	0	140	1,000	1,000	1,000	1,000
Średnia:					0,983	0,954	0,956	0,955

Tabela 5.8: Najlepsza uzyskana skuteczność dla klasyfikatora FLDA przy analizie typu pojazdu (zbiór testowy 40%)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	69	12	1	0	0,850	0,841	0,742	0,789
Dostawcze	18	20	2	0	0,867	0,500	0,625	0,556
Ciężarowe	4	0	35	0	0,968	0,897	0,921	0,909
Motocykl	2	0	0	85	0,991	0,977	1,000	0,988
Średnia:					0,919	0,804	0,822	0,810

Klasyfikator z lepszą skutecznością niż metoda NBC rozróżniała pojazdy ciężkie i motocykle. W przypadku zbioru testowego, pojazdy osobowe i dostawcze były rozróżniane z mniejszą precyzją.

Regresja liniowa

Tabela 5.9: Trafność klasyfikacji (ACC) Regresja liniowa (FV=67, 40% zbioru testowego)

Numer serii treningu	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
1	0,866	0,899	0,960	0,991	0,929
2	0,854	0,917	0,925	0,991	0,922
3	0,871	0,889	0,977	1,000	0,934
4	0,887	0,913	0,969	0,991	0,940
5	0,895	0,910	0,982	1,000	0,947
Średnio dla klasyfikatora	0,875	0,906	0,963	0,994	0,934

Tabela 5.10: Najlepsza uzyskana skuteczność dla klasyfikatora REG przy analizie typu pojazdu (zbiór treningowy 60%)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	134	0	1	0	0,946	0,993	0,876	0,931
Dostawcze	15	28	1	0	0,954	0,636	0,966	0,767
Ciężarowe	4	1	50	0	0,980	0,909	0,962	0,935
Motocykl	0	0	0	138	1,000	1,000	1,000	1,000
Średnia:					0,970	0,885	0,951	0,908

Tabela 5.11: Najlepsza uzyskana skuteczność dla klasyfikatora REG przy analizie typu pojazdu (zbiór testowy 40%)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	79	0	1	0	0,861	0,988	0,705	0,823
Dostawcze	26	19	1	0	0,875	0,413	0,864	0,559
Ciężarowe	7	3	23	0	0,946	0,697	0,920	0,793
Motocykl	0	0	0	89	1	1	1	1
Średnia:					0,920	0,774	0,872	0,794

W przypadku klasyfikatora bazującego na regresji liniowej, zauważamy mniejszy spadek czułości klasyfikatora między zbiorem treningowym a testowym. Znacznie gorzej wypada precyzja i *F-score*. Dla FLDA wynosiła kolejno PPV = 0,954 i *F-score* = 0,955, przy wyniku PPV = 0,885, *F-score* = 0,908 dla regresji liniowej.

Liniowy perceptron

Tabela 5.12: Trafność klasyfikacji (ACC) PLS - Częściowa regresja średniokwadratowa (FV=67, 40% zbioru testowego)

Numer serii treningu	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
1	0,879	0,916	0,956	1,000	0,938
2	0,878	0,915	0,956	0,9821	0,933
3	0,875	0,812	0,969	0,986	0,935
4	0,882	0,919	0,939	1,00	0,935
5	0,891	0,932	0,948	0,995	0,942
Średnio dla klasyfikatora	0,881	0,919	0,954	0,993	0,937

Tabela 5.13: Najlepsza uzyskana skuteczność dla klasyfikatora PLA przy analizie typu pojazdu (zbiór treningowy 60%)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	58	7	18	1	0,726	0,690	0,617	0,652
Dostawcze	17	0	16	0	0,800	0,000	0,000	0,000
Ciężarowe	17	1	17	2	0,742	0,459	0,315	0,374
Motocykl	2	0	3	89	0,953	0,947	0,967	0,957
Średnia:					0,805	0,524	0,475	0,496

Tabela 5.14: Najlepsza uzyskana skuteczność dla klasyfikatora PLA przy analizie typu pojazdu (zbiór testowy 40%)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowy	16	0	37	35	0,607	0,182	0,696	0,288
Mały dostawczy	6	0	17	15	0,763	0,000	0,000	0,000
Ciężarowy	0	0	11	15	0,639	0,423	0,169	0,242
Motocykl	1	0	0	95	0,649	0,990	0,594	0,742
Średnia:					0,664	0,339	0,365	0,318

Klasyfikator ten charakteryzował się niską skutecznością. Ograniczenie zasobów do trzech klas, nieznacznie poprawiło jakość klasyfikacji.

Liniowa analiza dyskryminacyjna

Tabela 5.15: Trafność klasyfikacji (ACC) LDA - Częściowa regresja średniokwadratowa (FV=67, 40% zbioru testowego)

Numer serii treningu	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
1	0,879	0,916	0,956	1,000	0,938
2	0,878	0,915	0,956	0,9821	0,933
3	0,875	0,812	0,969	0,986	0,935
4	0,882	0,919	0,939	1,00	0,935
5	0,891	0,932	0,948	0,995	0,942
Średnio dla klasyfikatora	0,881	0,919	0,954	0,993	0,937

Tabela 5.16: Najlepsza uzyskana skuteczność dla klasyfikatora LDA przy analizie typu pojazdu (zbiór treningowy 60%)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	128	11	0	0	0,949	0,921	0,941	0,931
Dostawcze	7	38	0	0	0,951	0,844	0,776	0,809
Ciężarowe	1	0	48	0	0,997	0,980	1,000	0,990
Motocykl	0	0	0	139	1,000	1,000	1,000	1,000
Średnia:					0,974	0,936	0,929	0,932

Tabela 5.17: Najlepsza uzyskana skuteczność dla klasyfikatora LDA przy analizie typu pojazdu (zbiór testowy 40%)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	66	9	1	0	0,875	0,868	0,759	0,810
Dostawcze	16	29	0	0	0,897	0,644	0,763	0,699
Ciężarowe	5	0	34	0	0,973	0,872	0,971	0,919
Motocykl	0	0	0	88	1,000	1,000	1,000	1,000
Średnia:					0,936	0,846	0,873	0,857

Tabela 5.18: Wyniki klasyfikacji dla zbiorów testowych (40%) przeprowadzonych dla wybranych klasyfikatorów

Klasyfikator	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
NBC	0,842	0,888	0,898	0,991	0,905
FLDA	0,894	0,908	0,973	0,995	0,943
REG	0,875	0,904	0,948	0,993	0,930
PLS	0,881	0,919	0,954	0,993	0,937
LDA	0,883	0,880	0,954	0,989	0,926


Podsumowując, skuteczność klasyfikacji typów pojazdów zamieszczono w tabeli 5.18. Najlepszy okazał się klasyfikator wykorzystujący liniową analizę dyskrimacyjną Fishera. Najczęstsze błędy stanowiło rozróżnienie pojazdów osobowych i dostawczych. Klasyfikacja treningowa, polegała na wizualnym przydzieleniu pojazdów do poszczególnych klas. Z akustycznego punktu widzenia, wpływ na zaklasyfikowanie jako pojazd dostawczy ma masa pojazdu, pośrednio przedstawiane za pomocą jego gabarytów i typ silnika -dla pojazdów dostawczych, znaczną większość stanowią silniki diesla.

W przypadku rozróżniania motocykli, nie zauważano znacznych odstęp przy klasyfikacji. Zdarzało się jedno zaklasyfikowanie pojazdu ciężarowego i osobowego jako motocykl, przy zastosowaniu zredukowanego wektora cech (15 parametrów). W testowanym zbiorze znalazły się pojazdy o sportowym charakterze, co mogło mieć wpływ na wyniki klasyfikacji. Zaś w zbiorze motocykli występowały zarówno typowe motocykle sportowe, jak i Harley-Davidson czy quady.

Akustyczna klasyfikacja pojazdów, może różnić się od prawnego podziału. Znacznie lepiej ukazuje jednak wpływ poszczególnych pojazdów na środowisko.

Redukcja wektora cech

Za pomocą metody PCA przeprowadzono proces selekcji parametrów kluczowych dla procesu detekcji. Wyniki dla etapu szkolenia klasyfikatora przedstawiono na rys. 5.15. Najdokładniej opisywaną klasą są motocykle. Trudność sprawiało rozróżnienie pojazdów osobowych i dostawczych. Parametry minimalnego wektora cech przedstawiono w tabeli 5.21. Większość parametrów dotyczy opisu widma sygnału. Uzyskane wyniki dla wektora długości 15 parametrów przedstawiono w tabelach: 5.19, 5.20



Rysunek 5.15: Wpływ długości wektora cech na jakość klasyfikacji ACC dla FLDA

Tabela 5.20: Najlepsza uzyskana skuteczność dla klasyfikatora FLDA przy analizie typu pojazdu, zredukowana liczba parametrów (40% - zbiór testowy)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	78	2	2	0	0,862	0,951	0,729	0,825
Dostawcze	23	16	1	0	0,869	0,400	0,696	0,508
Ciężarowe	6	5	25	3	0,924	0,641	0,893	0,746
Motocykl	0	0	0	87	0,986	1,000	0,967	0,983
Średnia:					0,910	0,748	0,821	0,766

Tabela 5.19: Najlepsza uzyskana skuteczność dla klasyfikatora FLDA przy analizie typu pojazdu, zredukowana liczba parametrów (60% - zbiór treningowy)

	O	D	C	M	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Osobowe	69	12	1	0	0,850	0,841	0,742	0,789
Dostawcze	18	20	2	0	0,867	0,500	0,625	0,556
Ciężarowe	4	0	35	0	0,968	0,897	0,921	0,909
Motocykl	2	0	0	85	0,991	0,977	1,000	0,988
Średnia:					0,919	0,804	0,822	0,810

Tabela 5.21: Spis parametrów składających się na najkrótszy wektor cech

Numer parametru	Nazwa parametru
1	Spectrum Mean
10	Rollff
34	MFCC21
47	MFCC34
48	MFCC35
53	Roughness Mean
58	Spectral Centroid
59	Spectral spread
62	Spectral kurtosis
67	Entropy of Spectrum

5.4.4 Detekcja stanu nawierzchni

W kontekście stanu nawierzchni istotna jest bieżąca informacja dotycząca opadów atmosferycznych (woda, śnieg, błoto pośniegowe na jezdni). Opracowywany system detekcji parametrów ruchu skupia się na stacjonarnych analizach, stąd detekcja defektów nawierzchni nie jest w pełni możliwa i jest realizowana na zasadzie detekcji dźwięków impulsowych (najazd na studzienkę, znaczący ubytek w jezdni generujący charakterystyczny dźwięk, uzależniony od liczby osi pojazdu). Innym podejściem mogłaby być długookresowa analiza poziomu hałasu generowanego przez pojazdy o zbliżonej strukturze ruchu. Wzrost wartości poziomu hałasu na przestrzeni tygo-

dni, miesięcy czy lat może wskazywać na degradację warstwy ścieralnej nawierzchni.

Obecność innych substancji na jezdni znacząco wpływa na przyczepność kół pojazdu do nawierzchni. Obecność płynów na nawierzchni zmniejsza siłę tarcia (3.1.1), co przekłada się na pogorszenie bezpieczeństwa w ruchu drogowym. Badania wykazały, iż mimo braku prawnych ograniczeń prędkości w przypadku niekorzystnych warunków pogodowych, kierowcy dobrowolnie ograniczają prędkość pojazdu w zależności od intensywności opadów [2, 77].

Wymagania techniczne i dostępne normy oceny stanu nawierzchni

Według normy PN-EN 155178-3:2011 obowiązuje pięć stanów nawierzchni ze względu na ilość cieczy wykrywaną przez czujnik, co przedstawiono w tab. 5.22. Wymagania dotyczące dokładności pracy urządzeń zależą od milimetrów opadu na godzinę, przy założeniu, że opad występował przez co najmniej 10 min. Rozdzielczość takich systemów jest stosunkowo mała i wynosi 0,1 mm/h. Jednak dokładność stawiana urządzeniom mieści się między $\pm 30\%$ dla opadów mniejszych niż 0,5 mm/h aż do $\pm 40\%$ przy opadzie powyżej 5 mm/h.

Tabela 5.22: Rozróżnienie stanu nawierzchni zgodnie z Normą PN-EN 155178-3:2011

Stan nawierzchni	Wynik pomiaru detektora
Sucha	brak wilgoci na powierzchni czujnika
Wilgotna	od 0,01 mm grubości warstwy cieczy na czujniku
Mokra	od 0,2 mm grubości warstwy cieczy na czujniku
Zalana	od 2 mm grubości warstwy cieczy na czujniku
Śliska	detekcja co najmniej obecności częściowo lub całkowicie skryształizowanej cieczy na powierzchni czujnika

Ze względu na duże ograniczenia akustycznego detektora dokładne określenie – zgodnie z normą - ilości wody na nawierzchni jest niemożliwe. Koszt drogowej stacji meteorologicznej jest dość znaczny, dlatego na polskich drogach jest stosunkowo mało takich instalacji. Wykorzystanie sensorów akustycznych wykrywających trzy stany nawierzchni w akustycznej detekcji może poprawić bezpieczeństwo ruchu drogowego i stanowi wartość dodaną systemów nadzoru ruchu drogowego.

Realizacja oceny stanu nawierzchni

W pierwszej kolejności zastosowano ten sam schemat przetwarzania wstępnego, jak wcześniej opisano to w rozdziale dotyczącym detekcji typu pojazdu. Na-

stępnie przeprowadzono klasyfikację stanu nawierzchni/warunków drogowych, przy czym stan nawierzchni rozumiany był jako obecność wody i innych opadów atmosferycznych na jezdni, a nie stan warstwy ścieralnej nawierzchni. Przyjęto potrzebę rozróżnienia trzech stanów hydrologicznych nawierzchni – jezdni sucha, mokra i śnieg (pokrywa śniegu grubości 2 cm, bez obecności soli, piasku).

Obserwacje (pojedyncze przejazdy) analizowano wg podziału na warunki nawierzchni. Rozkład udziałowy próbek dla wybranych trzech typów meteorologicznych przedstawiono w tabeli 5.16. Wektor cech FV wyjściowy składał się z 67 parametrów (załącznik B). W ramach badań wstępnych przeprowadzono eksperyment polegający na znalezieniu takich parametrów, aby różnica między nagraniami zarejestrowanymi dla różnych stanów nawierzchni była w jak największym stopniu zauważalna[68].

Wyniki dla parametru *jasność* i *Low Energy* przedstawiono w tabelach 5.23, 5.24. Należy zauważyć, w jakim stopniu parametry procesu ekstrakcji cech mają wpływ na rozpoznawanie niektórych systemów klasyfikacyjnych. Korzystając z algorytmu F-LDA, wyselekcjonowano 12 parametrów, które w wystarczający sposób pozwalały na rozróżnienie stanu jezdni. Wynik obserwacji przeprowadzonych w wybranej lokalizacji dla trzech warunków pogodowych i trzech cech: jasność, gęstość przejść przez zero i środek ciężkości pokazano na rysunku 5.16.

Tabela 5.23: Wyniki analizy dla parametru *brightness* w różnych konfiguracjach

Parametry procesu ekstrakcji cech			Jezdnia sucha		Jezdnia mokra	
Długość ramki analizy [ms]	Zakładkowanie [%]	Częstotliwość odcięcia [Hz]	Wartość średnia	Odchylenie standardowe	Wartość średnia	Odchylenie standardowe
25	25	1500	0,4972	0,0509	0,6254	0,0713
50	25	1500	0,5012	0,0433	0,6285	0,0669
25	25	3000	0,1652	0,0243	0,3258	0,0523
25	50	3000	0,1650	0,0245	0,3251	0,0519
50	50	3000	0,1663	0,0218	0,3274	0,0485

Tabela 5.24: Parametr Low-energy i jego wpływ na rozróżnianie stanu nawierzchni


Długość ramki analizy	Zakładkowanie	Próg reakcji	Sucha nawierzchnia	Mokra nawierzchnia
0,025	0,25	1	0,5586	0,5806
0,025	0,50	1	0,5592	0,5132
0,050	0,25	0,8	0,4138	0,3342
0,050	0,50	0,8	0,4160	0,4568
0,025	0,25	0,8	0,4467	0,3283
0,025	0,50	0,8	0,4088	0,4596

Tabela 5.25: Naiwny klasyfikator Bayesa 40% zbioru testowego. Macierz błędów i ocena skuteczności

	Sucha	Mokra	Śnieg	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Sucha	106	0	12	0,934	0,898	0,981	0,938
Mokra	2	40	12	0,944	0,778	1,00	0,851
Śnieg	0	0	51	0,901	1,00	0,680	0,810
Średnio:				0,920	0,880	0,887	0,866


Tabela 5.26: Liniowa analiza dyskryminacyjna Fishera 40% zbioru testowego. Macierz błędów i ocena skuteczności

	Sucha	Mokra	Śnieg	Jakość (ACC)	Precyzja (PPV)	Czułość	F-score
Sucha	108	0	10	0,953	0,915	1,000	0,956
Mokra	0	42	12	0,944	0,778	1,00	0,875
Śnieg	0	0	51	0,901	1,00	0,699	0,823
Średnio:				0,933	0,898	0,900	0,884



Rysunek 5.16: Wyniki trójwymiarowego wykresu rozrzutu dla obserwowanych zmian w stanie nawierzchni

Korzystając z pakietu NaN, przygotowano wytrenowane wcześniej klasyfikatory. Stosunek danych treningowych do testowych wynosił 3:2. Przebadano pięć klasyfikatorów, najlepsze okazały się: naiwny klasyfikator Bayesa (NBC), Liniowa Analiza Dyskryminacyjna (LDA) i jej odmiana w postaci algorytmu Fishera (FLDA). Wyniki eksperymentu przedstawiono w tab. 5.25 i 5.26.



Rysunek 5.17: Funkcja a) binary step i b) tangens hiperboliczny

Dla zebranego zestawu parametrów przygotowano sieć neuronową, (tzw. uczenie głębokie) składającą się z sześciu warstw ukrytych w konfiguracji: 12, 10, 8, 6, 4 i 3 ze składnikiem stałym (*bias*). Funkcją aktywacji dla warstw dla warstw 1-5 był tangens hiperboliczny (*tanh*), dla ostatniej zastosowano funkcję ramp (*binary setp*), która ze względu na binarną postać wektora odpowiedzi, znacząco poprawiła skuteczność klasyfikatora. Wykresy funkcji przedstawiono na rys. 5.17.

Schemat sieci przedstawiono na rys. 5.18. Sieć wytrenowano dla 60% obserwacji, stosując normalizację Min-Max (wzór 4.38 w rozdziale 4.3.1). Wyjściem z sieci był wektor $Y(1 \times 3)$, dla którego kodowanie przedstawiono w tab. 5.27.


Tabela 5.27: Wektor odpowiedzi klasyfikatora dla warunków meteorologicznych

$Y = [y_{11}, y_{12}, y_{13}] =$	Wyjście (label)
$Y = [1 \quad 0 \quad 0] =$	Sucha
$Y = [0 \quad 1 \quad 0] =$	Mokra
$Y = [0 \quad 0 \quad 1] =$	śnieg

Model klasyfikatora uzyskany został już po 10 iteracjach. Skuteczność sieci dla zbioru testowego wyniosła 95,86%. Przy testowaniu całego zbioru skuteczność osiągnęła wartość 97,74% (Tab. 5.28).

Tabela 5.28: Wyniki rozpoznawania warunków pogodowych z wykorzystaniem sieci neuronowej i zredukowanego za pomocą metody PCA zestawu parametrów (FV=12). Normalizacja min-max.

Wymiar zbioru	Skuteczność rozpoznawania [%]
Zbiór treningowy (60%)	99,70
Zbiór testowy(20%)	95,86
Cały zbiór (100%)	97,74



Rysunek 5.18: Schemat sieci i połączeń przy analizie stanu nawierzchni

5.5 Podsumowanie działania akustycznego klasyfikatora ruchu drogowego

Opracowana metoda detekcji i zliczania pojazdów uzyskuje zbliżone wyniki do komercyjnych urządzeń zapewniających - wg. producentów - 95% skuteczność. Rzeczywiste dane wyznaczone przez obserwatora wykazują jednak błędy w pomiarach przy wykorzystaniu omawianych urządzeń. Uzyskiwane błędy pomiaru są jednak dopuszczalne i akceptowalne w urządzeniach telematycznych drogowych. Analiza zajętości przekroju drogi, w którym znajduje się detektor, dostarcza informacji o odstępach między pojazdami, umożliwiając tym samym wyznaczenie przepustowości przekroju drogi.

Wytrenowane w badaniach klasyfikatory reagowały na cztery typy pojazdów. Pomyłki występujące między pojazdami lekkimi a dostawczymi wynikają z podobieństwa charakterystyk tych pojazdów. W szczególności dotyczy to rodzaju silnika (diesel) czy też gabarytów pojazdu.

Rozróżnienie stanu nawierzchni jest procesem szybszym (w kontekście algorytmów uczących się) i łatwiejszym niż klasyfikacja typów pojazdów. Podobnie, jak w systemach monitorowania warunków meteorologicznych, analiza stanu nawierzchni może odbywać się w określonym przedziale czasu (5, 10 lub 15 minut). Uzyskane wyniki klasyfikacji są możliwe do wykorzystania w rozwiązaniach praktycznych ze względu na wysoką skuteczność. Obliczona F-miara 0,95 pozwala wnioskować o dobrej stabilności proponowanych metod.

Rozdział 6

Podsumowanie i wnioski

Poniższy rozdział zawiera podsumowanie przeprowadzonych badań i nawiązuje do tez postawionych w rozprawie. Uwypuklono w nim autorskie rozwiązania oraz nakreślono kierunki rozwoju zaproponowanych w rozprawie metod. Propozycje zastosowania zaprojektowanych metod uwzględniają analizę wydajności opracowanych algorytmów w odniesieniu do dostępnych rozwiązań zaprezentowanych w rozdziale 3. W drugim podrozdziale, zawierającym możliwe kierunki dalszego rozwoju przedstawionych w rozprawie rozwiązań, zaprezentowano możliwe realizacje programowe i konfiguracje sprzętowe. Odniesiono się również do społeczno-prawnych aspektów systemów przetwarzania dźwięku dostępnych w miejscach publicznych.

6.1 Krytyczna ocena pracy

W rozprawie przybliżono wybrane metody rozpoznawania dźwięków w strumieniach sygnałów fonicznych w kontekście monitorowania ruchu drogowego. Przedstawiono uzyskaną skuteczność detekcji i klasyfikacji wybranych składników ruchu drogowego oraz możliwe zastosowanie zaproponowanych metod w praktycznych rozwiązaniach systemowych. Wyniki otrzymane w badaniach własnych odniesiono do skuteczności urządzeń komercyjnych. Opracowane przez autorkę metody, składające się na system akustycznej analizy ruchu drogowego, w przeprowadzonych testach uzyskały zadowalające skuteczności, porównywalne z danymi uzyskanymi z dostępnych urządzeń komercyjnych, pomimo że wykorzystano odmienny sposób pozyskiwania i analizy danych o ruchu drogowym. W przypadku, gdy było możliwe wykorzystanie sygnału wizyjnego jako danych sprawdzających (*ground truth*) uzyskana skuteczność detekcji składników ruchu drogowego była wyższa, co może świadczyć o przydatności opracowanej metody w praktycznych zastosowaniach.

W rozdziale 5.4.2 i 5.4.3 przedstawiono wyniki detekcji, zliczania i klasyfikacji typów pojazdów. Operacje wykonywano dla zadanych przedziałów obserwacji T. Stosując analizę sygnału, wyznaczano zajętość drogi w obrysie jej przekroju za pomocą opracowanego skryptu *DetectionStatistic.m*. Posłużył on do wyznaczania liczby pojazdów oraz podstawowych parametrów statystycznych związanych z czasem wystąpienia poszczególnych zdarzeń. Wykryte aktywne ramki za pomocą wytrenowanego klasyfikatora poddawane były ocenie w kontekście struktury rodzajowej ruchu (*TypeClassification.m*). Uzyskane skuteczności dla zbiorów treningowych, testowych i analizy strumienia ruchu (rozdział 5 i Załączniki do pracy (C) pozwoliły na udowodnienie **pierwszej tezy rozprawy** w następującym brzmieniu:

Możliwe jest określanie struktury liczbowo-rodzajowej potoku ruchu drogowego na podstawie analizy czasowo-częstotliwościowej hałasu emitowanego przez pojazdy, wspomaganą uczeniem maszynowym.

Rozdział 5.4.4 zawiera badania przeprowadzone na zebranych zbiorach danych obejmujących różne warunki pogodowe. Kontrola stanu nawierzchni i stopnia jej przyczepności w zależności od warunków meteorologicznych stanowi ważny aspekt bezpieczeństwa ruchu. Zaproponowana metoda monitorowania przyczepności opon pojazdu na jezdni poprzez analizę rejestrowanego sygnału fonicznego w pobliżu drogi daje dokładniejszy obraz stanu hydrologicznego jezdni niż stosowany odczyt wilgotności i temperatury nawierzchni. W tym kontekście przebadano kilka metod klasyfikacji, uzyskując zadowalające wyniki nawet dla znacznie zredukowanego wektora cech (12 parametrów). Uzyskane wyniki klasyfikacji, pozwalające na skuteczną detekcję obecności wody i śniegu na jezdni, udowadniają tym samym **drugą tezę rozprawy**:

Możliwe są detekcja i klasyfikacja stopnia suchości nawierzchni na podstawie wyników analizy akustycznej hałasu drogowego.

Przebadane w ramach pracy nagrania zostały w większości zarejestrowane i skategoryzowane przez autorkę rozprawy. Część nagrań zostało przygotowanych w ramach pracy magisterskiej oraz projektu inżynierskiego, w stosunku do których autorka pełniła rolę konsultanta prac.

Architektura systemu opracowana została na bazie dostępnych bibliotek metod matematycznych dotyczących przetwarzania dźwięku, jak i na własnym wkładzie programistycznym.

Rozwiązania autorskie

W ramach prowadzonych badań zaproponowano rozwiązania, które pozwoliły na prowadzenie automatycznej analizy ruchu drogowego. Było to możliwe dzięki zaproponowaniu szeregu rozwiązań i metod:

- Opracowanie indeksowanej bazy, w którym analiza sygnału fonicznego była wspomagana sygnałem wideo, stanowiącym (*ground truth*), co pozwoliło na uzyskanie wiarygodnych wyników;
- Uzyskanie danych, które typowo są zbierane w systemach ITS, przy wykorzystaniu tylko sygnału fonicznego;
- Zastosowanie metodologii zwanej inżynierią odwrotną w celu wyodrębnienia przybliżonej wielkości ruchu z poziomu hałasu rejestrowanego w danym obszarze;
- Zaproponowanie metody zliczania pojazdów do monitorowania ruchu na podstawie hałasu. Typowo, rejestrowany hałas jest wykorzystywany do uzyskania wskaźników, które pozwalają na zbadanie wpływu hałasu na środowisko (okolica), w którym pomiar jest dokonywany lub wykorzystuje się modele hałasu drogowego do predykcji liczby pojazdów, jednak bez weryfikacji i konfrontacji z rzeczywistym ruchem drogowym;
- Zaproponowane podejście analizy stanu nawierzchni umożliwia monitorowanie wpływu obecności wody na jezdni na warunki jezdne drogi – koszt drogowych stacji meteorologicznych jest znaczący i dlatego są one instalowane tylko w wybranych punktach drogi.
- Zaproponowano metody prognozy adaptacyjnej, w których eksperymentalnie dobierano próg wykorzystujący wartości średnie sygnału w buforze, wartość maksymalną, medianę oraz wariancję. Dodatkowo, w wykrywaniu zdarzeń w ruchu drogowym zastosowano badanie parametrów: płaskości i skrośności wartości RMS.

6.1.1 Proponowane zastosowania

Opracowany system przeznaczony jest do pogłębionej analizy ruchu drogowego na drogach zamiejskich. Jest urządzeniem pasywnym niezakłócającym pozyskiwanie danych z dostępnych systemów aktywnych, stosowanych zarówno w urządzeniach telematyki drogowej, jak i w systemach wspomagania jazdy (czujniki obecności, odległości instalowane w pojazdach, kamery wrażliwe na systemy LIDARowe).

W zależności od jakości zastosowanych przetworników dźwięku, urządzenie nie wymaga instalacji bezpośrednio przy jezdni. Mikrofony w ramach prowadzonych badań były umieszczane w odległości do 5 m od drogi. Minimalizuje to koszt utrzymania i serwisowania tego typu rozwiązania, nie wymagając zamknięcia pasa jezdni w czasie pracy proponowanego urządzenia, co jest konieczne w przypadku detektorów optycznych instalowanych bezpośrednio nad pasami ruchu czy też w instalowanych w nawierzchni pętli indukcyjnych. Dodatkowo, akustyczny monitoring jest w stanie objąć nadzorem szerszy obszar zainteresowań systemów telematyki niż typowe urządzenia wizyjne czy też wymagające bliskiego kontaktu z pojazdami czujniki magnetyczne i indukcyjne. Cecha ta jest szczególnie ważna przy wykrywaniu zdarzeń niebezpiecznych, typu: zderzenie pojazdów czy zbliżanie się pojazdu uprzywilejowanego. Akustyczna analiza ruchu drogowego jest odporna na warunki oświetleniowe, umożliwiając jednakową wydajność dla pracy w dzień i nocy (przy uwzględnieniu adaptacyjnego dostosowywania progu detekcji *TSHadaptation.m*). Ich wydajność nie jest ograniczona występowaniem trudnych warunków pogodowych np. mgły, a jej obecność może być wykryta jako zmiana przyczepności w skutek obecności wody. Poza analizą ruchu drogowego i użytecznością w kontekście algorytmów zarządzania ruchem, akustyczny monitoring zapewnia również informacje o generowanym hałasie drogowym.

6.2 Dalszy rozwój projektu

W obliczu dużych zmian technologicznych, które dokonują się w obszarze motoryzacyjnym (np. pojazdy autonomiczne - ang. *autonomous vehicles*) i pojazdy połączone (ang. *cooperative, connected vehicles*) można zastanowić się nad przydatnością stacjonarnych metod pomiaru parametrów ruchu. Jednak, pomimo iż idea „komunikujących się i współpracujących pojazdów” jest bardzo interesująca, zapewniając zarówno efektywne wykorzystanie sieci drogowych, jak i poprawę bezpieczeństwa i dbałość o środowisko, może nie być w pełni realizowalna w praktyce. Technologia zakłada, że wszyscy użytkownicy drogi (pojazdy, piesi i infrastruktura) będą dobrowolnie udzielać informacji dotyczących swojej lokalizacji i parametrów. Jednak w każdej sieci, znajdują się użytkownicy, którzy korzystając z tej sieci - blokują możliwość wysyłania własnych danych, zaś prawnie, nie można ich do tego zmusić. W przypadku szeroko rozumianej infrastruktury ruchu drogowego, skutki, jakie może wprowadzić takie zachowanie są znacznie poważniejsze niż przy typowych sieciach *peer-to-peer* (P2P), będących przykładem koegzystencji typowych użytkowników ak-

tywnych i użytkowników niekooperujących.

Ze względu na znaczące zaostżenia prawne dotyczące ochrony prywatności, szczególnie w kontekście rejestracji mowy, proces akustycznej analizy ruchu drogowego powinien odbywać się w obrębie detektora, bez możliwości rejestracji całego dostępnego wokół sygnału fonicznego. Dotyczy to głównie lokalizacji, w których mogą znajdować się piesi. Docelowo, planowane jest przeniesienie działania algorytmów na urządzenia rejestrujące, instalowane bezpośrednio przy drodze, tak aby do centrów zarządzania ruchem docierała jedynie informacja o wybranych parametrach ruchu drogowego w zadanych odstępach czasowych.

Przeprowadzono również pierwsze próby implementacji akustycznego detektora ruchu w oparciu o kartę Arduiono wyposażoną w stereofoniczne czujniki dźwięku i w analogowy filtr pasmowy. Wyniki analiz przedstawiono we współautorskiej publikacji *An application of acoustic sensors for the monitoring of road traffic* (SPA 2018)[85].

Kolejne prace rozwojowe dotyczące projektu obejmują opracowanie systemów detekcji zdarzeń - pojazdów uprzywilejowanych, kolizji drogowych, dźwięków klaksonów, znajdując tym samym kolejne odniesienia do problemów bezpieczeństwa w ruchu drogowym.

Bibliografia

- [1] H. Abdi. Normalizing data. *Encyclopedia of Research Design*, 2002.
- [2] M. Agarwal, T. H. Maze, R. Souleyrette. Impacts of weather on urban freeway traffic flow characteristics and facility capacity. *Proceedings of the 2005 mid-continent transportation research symposium*, strony 18–19, 2005.
- [3] F. Alías, J. C. Socoró, X. Sevillano. A review of physical and perceptual feature extraction techniques for speech, music and environmental sounds. *Applied Sciences*, 6(5), 2016. Article number143.
- [4] P. Allaby. An evaluation of the safety and operational impacts of a candidate variable speed limit control strategy on an urban freeway. 2006.
- [5] E. Allamanche, T. Kastner, R. Wistorf, N. Lefebvre, J. Herre. Music genre estimation from low level audio features. *Audio Engineering Society Conference: 25th International Conference: Metadata for Audio*, Jun 2004.
- [6] F. Angione, C. Novak, P. D'Angela, H. Ule. Acoustic localization of an electronic emergency siren. *Proceedings of Meetings on Acoustics 172ASA*, wolumen 29, strona 030004. ASA, 2016.
- [7] Apple Co. Siri - oficjalna strona producenta. (dostęp: marzec 2018 r.
- [8] AS Direct, AutoDNA. Normy Euro a silniki stosowane w europejskich samochodach. <https://www.autodna.pl/blog/normy-euro-a-silniki-stosowane-w-europejskich-samochodach/>, 2018. (dostęp październik 2018 r.).
- [9] R. Bernhard, R. L. Wayson, J. Haddock, N. Neithalath, A. El-Aassar, J. Olek, T. Pellinen, W. J. Weiss. An introduction to tire/pavement noise of asphalt pavement. *Institute of Safe, Quiet and Durable Highways, Purdue University*, 2005.
- [10] K. Birr, K. Jamroz, W. Kustra. Analiza czynników wpływających na prędkość pojazdów transportu zbiorowego na przykładzie gdańska. *Prace naukowe Politechniki Warszawskiej-Transport*, 96, 2013.
- [11] T. R. Board. *Highway Capability Manual*. National Research Council. ISBN 0-309-06681-6.

-
- [12] J. Bohatkiewicz. Modelowanie i ocena rozwiązań chroniących przed hałasem drogowym. *Monografie. Politechnika Lubelska*, 2017.
- [13] J. Breebaart, M. F. McKinney. Features for audio classification. *Algorithms in Ambient Intelligence*, strony 113–129. Springer, 2004.
- [14] G. Cerrato. Automotive sound quality – powertrain, road and wind noise. <http://www.sandv.com/downloads/0904cerr.pdf>, 2009. (dostęp 10.08.2018 r.).
- [15] J. Chodur, M. Kieć, K. Ostrowski. Wybrane aspekty analizy warunków ruchu na odcinkach dróg dwupasowych, dwukierunkowych z wykorzystaniem metody hcm-2010. *Logistyka*, (3, CD 1):687–696, 2015.
- [16] S. Chu, S. Narayanan, C. . J. Kuo, M. J. Mataric. Where am i? scene recognition for mobile robots using audio features. *2006 IEEE International Conference on Multimedia and Expo*, strony 885–888, July 2006.
- [17] Classeval portal. Classifier evaluation with imbalanced datasets – knowledge base of performance evaluation measures for binary classification models. <https://classeval.wordpress.com/>. (dostęp listopad 2018 r.).
- [18] E. Commission. Quality of gasoline and diesel fuel used for road transport in the european union - first annual report (reporting years 2001 and 2002), 2004.
- [19] M. Cooke, G. J. Brown, M. Crawford, P. Green. Computational auditory scene analysis: listening to several things at once. *Endeavour*, 17(4):186 – 190, 1993.
- [20] R. Crist. Siri, alexa or google: Which voice helper is best for you? - cnet. <https://www.cnet.com/news/apple-siri-amazon-alexa-or-google-assistant-which-voice-helper-is-best-for-you/>, kwiecień 2018. (dostęp: wrzesień 2018 r.).
- [21] A. Czyzewski, K. Marciniuk, B. Kostek. Dynamic road traffic density estimation employing noise mapping with the use of grid supercomputing. *The Journal of the Acoustical Society of America*, 139(4):2006–2006, 2016.
- [22] A. Dąbrowski, J. Skalski. Obudowy urządzeń elektrycznych-funkcje i badania. *Bezpieczeństwo Pracy: nauka i praktyka*, (2):18–23, 1999.
- [23] P. D’Angela. Emergency vehicle siren noise effectiveness, 2013.
- [24] Defense Advanced Research Projects Agency. Oficjalna strona DARPA. <https://www.darpa.mil/our-research>. (dostęp: maj 2018 r.).
- [25] H. Dezani, R. D. Bassi, N. Marranghello, L. Gomes, F. Damiani, I. N. da Silva. Optimizing urban traffic flow using genetic algorithm with petri net analysis as fitness function. *Neurocomputing*, 124:162 – 167, 2014.

-
- [26] M. D. Dobrzański. Zastosowanie technik deep learning w problematyce rozpoznawania akordów muzycznych.
- [27] L. Dunai, G. Peris-Fajarnés, E. Lluna, B. Defez. Sensory navigation device for blind people. *The Journal of Navigation*, 66(3):349–362, 2013.
- [28] Z. Engel. *Ochrona środowiska przed drganiami i hałasem*. Wydaw. Naukowe PWN, 2001.
- [29] European Commission. EU legislation on passenger car type approval and emissions standards. Raport instytutowy, European Union, 2016.
- [30] F. Eyben. *Real-time speech and music classification by large audio feature space extraction*. Springer International Publishing, 2016.
- [31] H. Fastl, E. Zwicker. *Psychoacoustics: facts and models*, wolumen 22. Springer Science & Business Media, 2006.
- [32] H. Fuchs, S. Tuff, C. Bustad. Dialogue enhancement—technology and experiments. *EBU Technical review*, 2:1, 2012.
- [33] S. Gaca, K. Jamroz, M. Budzyński, M. K. and. Lech Michalski, J. Oskarbski, M. Wroński. Wytyczne zarządzania prędkością na drogach samorządowych. Raport instytutowy, Politechnika Krakowska, Politechnika Gdańska, Fundacja Rozwoju Inżynierii Lądowej, Krajowa Rada Bezpieczeństwa Ruchu Drogowego, 2016.
- [34] S. Gaca, W. Suchorzewski, M. Tracz. *Inżynieria Ruchu Drogowego. Teoria i praktyka*. WKiŁ, 2008.
- [35] GDDKiA. Test stanowiska ważenia pojazdów w ruchu sprawdzający poziom detekcji, identyfikacji i klasyfikacji pojazdów. (dostęp: lipiec 2018 r.).
- [36] Główny Urząd Statystyczny. Bank Danych Lokalnych. Raport instytutowy, 6 2018. (dostęp: marzec 2018 r.).
- [37] G.-Z. GmbH. The central portal for all european environmental zones. <https://www.green-zones.eu/en.html>, aug 2018.
- [38] I. Goodfellow, Y. Bengio, A. Courville. *Deep Learning*. MIT Press, 2016.
- [39] F. Gouyon, F. Pachet, O. Delerue, i in. On the use of zero-crossing rate for an application of classification of percussive sounds. *Proceedings of the COST G-6 conference on Digital Audio Effects (DAFX-00)*, Verona, Italy, 2000.
- [40] T. Grill, J. Schlüter. Two convolutional neural networks for bird detection in audio signals. *Signal Processing Conference (EUSIPCO), 2017 25th European*, strony 1764–1768. IEEE, 2017.
- [41] A. Grochowski. Architektura frame w projektach its - „opis metodyki opracowania architektury its”.

-
- [42] C. Hammerschmidt. Hyundai buys into v2x technology company autotalks. [http : / / www . eenewsautomotive . com / news / hyundai-buys-v2x-technology-company-autotalks](http://www.eenewsautomotive.com/news/hyundai-buys-v2x-technology-company-autotalks), 11 2018. (dostęp: wrzesień 2018 r.).
- [43] C. Harlow, Y. Wang. Acoustic accident detection system. *ITS Journal-Intelligent Transportation Systems Journal*, 7(1):43–56, 2002.
- [44] K. Hatori, Y. Saijo, Y. Hagiwara, Y. Naganuma, K. Igari, M. Iikubo, K. Kobayashi, K. Sasaki. Acoustic diagnosis device for dentistry. K. Sasaki, O. Suzuki, N. Takahashi, redaktorzy, *Interface Oral Health Science 2016*, strony 181–201, Singapore, 2017. Springer Singapore.
- [45] C. J. Hawthorn, K. P. Weber, R. E. Scholten. *Traffic Detector Handbook:Third Edition*. FHWA, 2010.
- [46] P. Hill. Google home is more likely to answer your questions than amazon’s alexa. [https : / / www . neowin . net / news / google-home-is-more-likely-to-answer-your-questions-than-amazons-alexa](https://www.neowin.net/news/google-home-is-more-likely-to-answer-your-questions-than-amazons-alexa), 2017. (dostęp: wrzesień 2018 r.).
- [47] R. Hoeldrich. An optimized model for the objective assessment of roughness sensations in vehicle noise. *AVL-Sound Engineering Conference, Graz*, strony 22–23, 1999.
- [48] F. Holmes. V2x will connect the car with the outside world (soon). [https : / / www . automotiveworld . com / articles / v2x-will-connect-the-car-with-the-outside-world-soon/](https://www.automotiveworld.com/articles/v2x-will-connect-the-car-with-the-outside-world-soon/), 9 2018. (dostęp: wrzesień 2018 r.).
- [49] A. Hulewicz, Z. Krawiecki. Narzędzie statystyczne w procesie normalizacji wyników pomiarów. *Electrical Engineering*, 2016(88):251–260, 2016.
- [50] J. Isotalo. Basics of statistics. *Basics of Statistics course, University of Tampere, Finland*.
- [51] R. Iyer, J. Bilmes. Algorithms for approximate minimization of the difference between submodular functions, with applications. *arXiv preprint arXiv:1207.0560*, 2012.
- [52] K. Jajuga, M. Walesiak. Standardisation of data set under different measurement scales. *Classification and information processing at the turn of the millennium*, strony 105–112. Springer, 2000.
- [53] G. James, D. Witten, T. Hastie, R. Tibshirani. *An introduction to statistical learning*, wolumen 112. Springer-Verlang New Year, 2013.
- [54] K. Jamroz. The impact of road network structure and mobility on the national traffic fatality rate. *Procedia-Social and Behavioral Sciences*, 54:1370–1377, 2012.

-
- [55] K. Jamroz, J. Oskarbski. Tristar-trojmiejski inteligentny system transportu aglomeracyjnego. *Transport Miejski i Regionalny*, 7:08, 2006.
- [56] K. Jamroz, J. Oskarbski. Inteligentny system transportu dla aglomeracji trójmiejskiej. *Telekomunikacja i techniki informacyjne*, strony 66–76, 2009.
- [57] K. Jamroz, J. Oskarbski, L. Gumińska, W. Kustra. Zastosowanie wielopoziomowego modelu ruchu dla systemu tristar. *Zeszyty Naukowo-Techniczne Stowarzyszenia Inżynierów i Techników Komunikacji w Krakowie. Seria: Materiały Konferencyjne*, (1 (97)):101–115, 2012.
- [58] G. Jansson. Traffic control with standard genetic algorithm. a simulated optimization control of traffic intersection. 2011.
- [59] M. Janvier, X. Alameda-Pineda, L. Girin, R. Horaud. Sound representation and classification benchmark for domestic robots. *2014 IEEE International Conference on Robotics and Automation (ICRA)*, strony 6285–6292, 2014.
- [60] Kaggle.com. Portal dt. uczenia maszynowego. <https://www.kaggle.com/datasets>. (dostęp: wrzesień 2018 r.).
- [61] O. Kalinli, S. Sundaram, S. Narayanan. Saliency-driven unstructured acoustic scene classification using latent perceptual indexing. *Multimedia Signal Processing, 2009. MMSP'09. IEEE International Workshop on*, strony 1–6. IEEE, 2009.
- [62] Kancelaria Senatu, Biuro Analiz i Dokumentacji. Organizacja służb ratownictwa medycznego w wybranych państwach, 2013.
- [63] Y. Kawai, F. Tomita. A support system for visually impaired persons to understand three-dimensional visual information using acoustic interface. *Object recognition supported by user interaction for service robots*, wolumen 3, strony 974–977 vol.3, Aug 2002.
- [64] Komisja Unii Europejskiej. Rozporządzenie komisji (UE) nr 459/2012 dla lekkich pojazdów pasażerskich i użytkowych., 2012.
- [65] J. Kotus, M. Szczodrak, K. Marciniuk, A. Czyzewski, B. Kostek. Creating dynamic psychoacoustic maps of hearing threats for outdoor concerts employing supercomputing grid. *Audio Engineering Society Convention 136*. Audio Engineering Society, 2014.
- [66] M. Kruczyna, P. Mackiewicz, R. Wardega. Drogi, ulice węzły. Wykłady do przedmiotu studiów I stopnia dziennych rok 3, info o predkosciach.
- [67] R. D. Kuhne. Freeway control using a dynamic traffic flow model and vehicle reidentification techniques. *Transportation Research Record*, (1320):251–259, 1991. (dostęp: kwiecień 2018 r.).

-
- [68] A. Kurowski, K. Marciniuk, B. Kostek. Separability assessment of selected types of vehicle-associated noise. *Multimedia and Network Information Systems*, strony 113–121. Springer, 2017.
- [69] O. Lartillot. Mirtoolbox user's manual. *Finnish Centre of Excellence in Interdisciplinary Music Research*, 2011.
- [70] G. Leanna. Oslo to ban cars in its city center. *Business Insider*, 21 October 2015.
- [71] G. Leanna. Madrid, Spain is banning cars from its crowded city center. *Business Insider*, 7 January 2017.
- [72] K. Lejda, K. Łakota. Zastosowanie systemów ITS do sterowania ruchem ulicznym w miastach na przykładzie dotychczasowych rozwiązań. http://publications.ntu.edu.ua/visnyk/27_2013/024-030.pdf, 2013. (dostęp: lipiec 2018 r.).
- [73] K. Lemke. The new German highway capacity manual (hbs 2015). *Transportation Research Procedia*, 15:26 – 35, 2016. International Symposium on Enhancing Highway Performance (ISEHP), June 14-16, 2016, Berlin.
- [74] A. Lerch. *An introduction to audio content analysis: Applications in signal processing and music informatics*. Wiley-IEEE Press, 2012.
- [75] H. Li, Z. Tang, X. Fei, K. Chao, M. Yang, C. He. A survey of audio mir systems, symbolic mir systems and a music definition language demo-system. *2017 IEEE 14th International Conference on e-Business Engineering (ICE-BE)*, strony 275–281, Nov 2017.
- [76] P. Liang, S. Ermon. Lecture 2: Machine learning I, 2017.
- [77] W. Liang, M. Kyte, F. Kitchener, P. Shannon. Effect of environmental factors on driver speed: A case study. *Transportation Research Record: Journal of the Transportation Research Board*, (1635):155–161, 1998.
- [78] J. G. Lilly. Engine exhaust noise control.
- [79] J. M. Loomis, R. G. Golledge, R. L. Klatzky. Navigation system for the blind: Auditory display modes and guidance. *Presence*, 7(2):193–203, 1998.
- [80] K. Łopatka. *Adaptive system for recognition of sounds indicating threats to security of people and property employing parallel processing of audio data streams*. Praca doktorska, Politechnika Gdańska, 2015.
- [81] P. Lula. Wstępna analiza danych w procesie modelowania przy użyciu sieci neuronowych. *Zeszyty Naukowe / Akademia Ekonomiczna w Krakowie*, 1997(493):35–48, 1997.

-
- [82] R. Lyon. A computational model of filtering, detection, and compression in the cochlea. *ICASSP '82. IEEE International Conference on Acoustics, Speech, and Signal Processing*, wolumen 7, strony 1282–1285, May 1982.
- [83] K. Marciniuk, B. Kostek. ” creating a numerical model of noise conditions based on the analysis of traffic volume changes in cities with low and medium structure. *Archives of Acoustics*, 40:438–439, 2015.
- [84] K. Marciniuk, B. Kostek, A. Czyżewski. Traffic noise analysis applied to automatic vehicle counting and classification. *International Conference on Multimedia Communications, Services and Security*, strony 110–123. Springer, 2017.
- [85] K. Marciniuk, M. Szczodrak, A. Czyżewski. An application of acoustic sensors for the monitoring of road traffic. 2018.
- [86] K. Marciniuk, M. Szczodrak, B. Kostek. Performance of noise map service working in cloud computing environment. *Archives of Acoustics*, 41(2):297–302, 2016.
- [87] D. Miloradović, J. Glisovic, J. Lukić. Regulations on road vehicle noise – trends and future activities. *International Journal "Mobility and Vehcile Mechanics"*, 43:59–72, 03 2017.
- [88] Minister Środowiska. Rozporządzenie ministra Środowiska z dnia 1 października 2012 r. zmieniające rozporządzenie w sprawie dopuszczalnych poziomów hałasu w środowisku. Dz.U. 2012 poz. 1109, 2012.
- [89] M. Minsky, S. A. Papert. *Perceptrons: An introduction to computational geometry*. MIT press, 1969.
- [90] M. MN. Noise pollution: The sound behind heart effects. *Environmental Health Perspectives*, 11(115):A536–A537, 2007.
- [91] D. S. Moore, S. Kirkland. *The basic practice of statistics*, wolumen 2. WH Freeman New York, 2007.
- [92] MPER-7. Strona projektu - MPEG7 - ISO/IEC 15938. <http://mpeg7.org>. (dostęp listopad 2018 r.).
- [93] B. W. B. M. Münzel T, Gori T. Cardiovascular effects of environmental noise exposure. *European Heart Journal*, 13(35):829–836, 2014.
- [94] Nanalyze.com. 6 vehicle-to-vehicle (v2v) communication startups - nanalyze. <https://www.nanalyze.com/2017/04/6-vehicle-v2v-communication-startups/>, 4 2017. (dostęp z 12.04.2018).
- [95] M. Nawafleh, N. Al-Kloub. Acoustic diagnosis technique for machine condition monitoring. *EDITORIAL BOARD*, 3(4):268, 2009.
- [96] M. Nilsson, M. Mutschler, J. Sundstorm. Strona projektu - ID3.org - The Audience is informed. <http://id3.org/>. (dostęp listopad 2018).

-
- [97] J. J. Noda, C. M. Travieso, D. Sánchez-Rodríguez. Fusion of linear and mel frequency cepstral coefficients for automatic classification of reptiles. *Applied Sciences*, 7(2), 2017.
- [98] Normy. PN-ISO 1996-1:2006 - Akustyka - Opis, pomiary i ocena hałasu środowiskowego – Część 1: Wielkości podstawowe i procedury oceny, 2006.
- [99] A. Nowak-Brzezińska. Analiza dyskryminacyjna, konspekt do zajęć - statystyczne metody analizy danych. http://zsi.tech.us.edu.pl/~nowak/smad/SMAD_lda.pdf, styczeń 2010. (dostęp wrzesień 2018 r.).
- [100] Octave. Octave forge. <https://octave.sourceforge.io/>. (dostęp lipiec 2018 r.).
- [101] Octave. Octave forge - the 'lftfat' package. <https://octave.sourceforge.io/lftfat/index.html>. (dostęp lipiec 2018 r.).
- [102] Octave. Octave forge - the 'nan' package. <https://octave.sourceforge.io/nan/index.html>. (dostęp lipiec 2018 r.).
- [103] Octave. Octave forge - the 'signal' package. <https://octave.sourceforge.io/signal/index.html>. (dostęp lipiec 2018 r.).
- [104] L. Oroszlány. *Octave System Sound Processing Library*. Praca doktorska, Masarykova univerzita, Fakulta informatyki, 2012.
- [105] M. Papageorgiou, E. Kosmatopoulos, I. Papamichail. Effects of variable speed limits on motorway traffic flow. *Transportation Research Record: Journal of the Transportation Research Board*, (2047):37–48, 2008.
- [106] R. Parikh, A. Mathai, S. Parikh, G. C. Sekhar, R. Thomas. Understanding and using sensitivity, specificity and predictive values. *Indian journal of ophthalmology*, 56(1):45, 2008.
- [107] Parlament Europejski i Rada UE. Dyrektywa Parlamentu Europejskiego i Rady 2010/40/UE z dnia w sprawie ram wdrażania inteligentnych systemów transportowych w obszarze transportu drogowego oraz interfejsów z innymi rodzajami transportu, 2010.
- [108] D. Peleg, R. Meir. A feature selection algorithm based on the global minimization of a generalization error bound. *Advances in neural information processing systems*, strony 1065–1072, 2005.
- [109] Polski Urząd Norm. Polska Norma PN-92/S-04051 - pojazdy samochodowe i motorowery. dopuszczalny poziom hałasu zewnętrznego. wymagania i badania.
- [110] Rada Wspólnot Europejskich. Dyrektywa Rady z dnia 6 lutego 1970 r. w sprawie zbliżenia ustawodawstw Państw Członkowskich odnoszących się do dopuszczalnego poziomu hałasu i układu wydechowego pojazdów silnikowych.
- [111] D. Rasała, D. Malina. Uogólniony liniowy klasyfikator fishera. *Zeszyty Naukowe Akademii Marynarki Wojennej*, 55(2 (197)):99–118, 2014.

-
- [112] Ż. Renata, S. Aleksander. Fundamentalny diagram ruchu – teoria i praktyka. *Logistyka*, 6, 2014.
- [113] F. Rosenblatt. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6):386, 1958.
- [114] J. Sadowski. Kształtowanie klimatu akustycznego środowiska i jego ochrona przed hałasem i drganiami. *Prace Instytutu Techniki Budowlanej*, 28(2-3):50–61, 1999.
- [115] Salford Innovation Research Centre (SIRC). An introduction to Sound Quality testing. <https://www.salford.ac.uk/research/sirc/research-groups/acoustics/psychoacoustics/sound-quality-making-products-sound-better/accordion/sound-quality-testing>. (dostęp listopad 2017 r.).
- [116] M. Sammarco, M. Detyniecki. Crashzam: Sound-based car crash detection. *VEHITS*, strony 27–35, 2018.
- [117] J. Santa, F. Pereñíguez, A. Moragón, A. F. Skarmeta. Vehicle-to-infrastructure messaging proposal based on cam/denm specifications. *Wireless Days (WD), 2013 IFIP*, strony 1–7. IEEE, 2013.
- [118] T. R. . M. Services. Scats: The benchmark in urban traffic control.
- [119] S. Shaheen, R. Finson. Intelligent transportation systems, 12 2013.
- [120] D. Shete, S. Patil, S. Patil. Zero crossing rate and energy of the speech signal of devanagari script. *IOSR-JVSP*, 4(1):1–5, 2014.
- [121] SiemensAG. Siemens traffic detectors. from induction loops to radar technology: The right detector system for any application, 2018. (dostęp: wrzesień 2018 r.).
- [122] M. Siergiejczyk, K. Krzykowska, K. Tatar. Wdrażanie usługi its monitorowania i nadzoru ruchu pojazdów w obszarze miejskim. *Autobusy: technika, eksploatacja, systemy transportowe*, 17, 2016.
- [123] J. Singer, N. Lerner, C. Baldwin, E. Traube. Auditory alerts in vehicles: Effects of alert characteristics and ambient noise conditions on perceived meaning and detectability. *Conference on the*, wolumen 1, strony 1–14, 2015.
- [124] S. Singh, S. Payne, J. Mackrill, P. Jennings. Using virtual environments as a tool to evaluate electric vehicle sounds. 2014.
- [125] S. Singh, S. R. Payne, P. A. Jennings. Toward a methodology for assessing electric vehicle exterior sounds. *IEEE Transactions on Intelligent Transportation Systems*, 15(4):1790–1800, 2014.
- [126] D. S. P. M. Song, Yading. A survey of music recommendation systems and future perspectives. *9th International Symposium on Computer Music Modeling and Retrieval (CMMR)*, 2012.

-
- [127] M. Sørensen, M. Hvidberg, Z. J. Andersen, R. B. Nordsborg, K. G. Lillelund, J. Jakobsen, A. Tjønneland, K. Overvad, O. Raaschou-Nielsen. Road traffic noise and stroke: a prospective cohort study. *European heart journal*, 32(6):737–744, 2011.
- [128] A. P. Sovik. 20 tunnels installed with acoustic tunnel monitoring. *TUNNTECH TM, Global News*, 2017. (dostęp: czerwiec 2018 r.).
- [129] J. Stefanowski. Algorytmy indukcji reguł decyzyjnych w odkrywaniu wiedzy. *Wydawnictwo Politechniki Poznańskiej, Poznań*, 2001.
- [130] F. Systems. Traffic video detection and monitoring. discover a wide range of applications. (dostęp: lipiec 2018 r.).
- [131] M. Szelag. Wstępne przetwarzanie i analiza danych, 2015.
- [132] J. Tejedor, J. Macias-Guarasa, H. F. Martins, J. Pastor-Graells, P. Corredera, S. Martin-Lopez. Machine learning methods for pipeline surveillance systems based on distributed acoustic sensing: A review. *Applied Sciences*, 7(8), 2017.
- [133] E. Trzensik, M. Światłoń. Wpływ implementacji norm emisji spalin Euro 5 i Euro 6 na przemysł motoryzacyjny w aspekcie wdrażania nowych technologii i wzrostu kosztów. *Zeszyty Naukowe. Transport/Politechnika Śląska*, strony 83–98, 2011.
- [134] S. Uhlich, F. Giron, Y. Mitsufuji. Deep neural network based instrument extraction from music. *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, strony 2135–2139, April 2015.
- [135] Unia Europejska. Dyrektywa 2002/49/EC of the european parliament and the council of 25 june 2002 relating to the assessment and management of environmental noise. *Official Journal of the European Communities, L*, 189(18.07):2002, 2002.
- [136] Unia Europejska. Dyrektywa 2008/50/EC Parlamentu Europejskiego - dot. jakości powietrza w Europie, 2008.
- [137] S. C. Unit. Links between noise and air pollution and socioeconomic status, 2016.
- [138] Urząd Miasta Gdańsk. Portal stałego monitoringu hałasu komunikacyjnego Miasta Gdańska. <http://mapaakustyczna.gdansk.gda.pl/VisMap/apps/gdansk/public/>, 2018. (dostęp z 20.10.2018 r.).
- [139] V. Vencovský. *Assessment of Sound by Means of an Auditory Model-Prediction og Roughness*. Praca doktorska, 2015.
- [140] Vidhya Analytics. 25 open datasets for deep learning every data scientist must work with. <https://www.analyticsvidhya.com/blog/2018/03/comprehensive-collection-deep-learning-datasets/>. (dostęp: luty 2018 r.).

-
- [141] Vidhya Analytics. Deep learning archives - analytics vidhya. <https://www.analyticsvidhya.com/blog/category/deep-learning/>. (dostęp maj 2018).
- [142] L. Vinsel. The Man Who Invented Intelligent Traffic Control a Century Too Early. *IEEE Spectrum: Technology, Engineering, and Science News*, 7 2016. (dostęp: luty 2018 r.).
- [143] M. Weinberger. Amazon echo and alexa history: From speaker to smart home hub. <https://www.businessinsider.com/amazon-echo-and-alexa-history-from-speaker-to-smart-home-hub-2017-5?IR=T>, 2017. (dostęp: wrzesień 2018 r.).
- [144] J. Weston, S. Mukherjee, O. Chapelle, M. Pontil, T. Poggio, V. Vapnik. Feature selection for svms. *Advances in neural information processing systems*, strony 668–674, 2001.
- [145] J. S. C. Zach Wendt. Saved by the sensor: Vehicle awareness in the self-driving age, 2018. (dostęp: czerwiec 2018 r.).
- [146] M. Ziemska, M. Śrubka. Analiza porównawcza inteligentnych systemów sterowania ruchem drogowym, metoda balance i metoda scats. *Prace Wydziału Nawigacyjnego Akademii Morskiej w Gdyni*, 2016.
- [147] A. Świercz, J. Żera. Model of auditory filters and mpeg-7 descriptors in sound recognition. strony 200–211, 08 2014.

Dodatek A

Parametry drogowe - podsumowanie

Tabela A.1: Parametry ruchu, ich funkcjonalność i metody pomiaru

Tabela parametrów		
Parametr	Znaczenie	Sposób pomiaru
Średnia prędkość w potoku ruchu	Wyznaczana na podstawie zarejestrowanych prędkości pojazdów, uśredniana dla wybranego przedziału czasu (1min, 5min, 10min, 15min) w zależności od wybranego modelu.	Mierzenie w oparciu o sensory tematyki drogowej, wyznaczana algorytmicznie na podstawie zebranych danych: pętle indukcyjne, kamery VIP, sensory mikrofalowe i optyczne.
Odchylenie standardowe prędkości (ang. <i>SDS, Standard Deviation of Speed</i>)	Wyznaczana na podstawie zarejestrowanych prędkości pojazdów dla wybranego przedziału czasu (1min, 5min, 10min, 15min) w zależności od wybranego modelu. Docelowo, należy dążyć do zmniejszenia wartości.	Mierzenie w oparciu o sensory tematyki drogowej, wyznaczana algorytmicznie na podstawie zebranych danych: pętle indukcyjne, kamery VIP, sensory mikrofalowe i optyczne.
Prędkość maksymalna / minimalna	Wyznaczana na podstawie zarejestrowanych prędkości pojazdów dla wybranego przedziału czasu (1min, 5min, 10min, 15min) w zależności od wybranego modelu.	Mierzenie w oparciu o sensory tematyki drogowej, wyznaczana algorytmicznie na podstawie zebranych danych: pętle indukcyjne, kamery VIP, sensory mikrofalowe i optyczne.
Średnia długość kolejki (ang. <i>Mean Queue Length</i>)	Stosowana przykładowo przy wyznaczaniu długości oczekiwania na wjazd na/ wyjazd z autostrady. W mniejszych modelach dla ustalania czasu oczekiwania na zmianę świateł.	Wyznaczane na podstawie zarejestrowanych pojazdów w danych punktach pomiarowych, uwzględniając przy tym pojemność danego odcinka drogi. Łatwiejsze to wyznaczenia na podstawie monitoringu. Inne proponowane podejście opiera się o zależność między liczbą pojazdów, rejestrowanymi prędkościami i odstępami między pojazdami.

Kontynuacja tabeli A.1

Parametr	Znaczenie	Sposób pomiaru
Średni czas podróży	Miara ekonomiczna, wyznacza średni czas potrzebny na pokonanie danego odcinka drogi.	Rejestracja przejazdów konkretnych pojazdów w kilku punktach sieci drogowej za pomocą: ANPR (automatyczne rozpoznawanie tablic rejestracyjnych), Bluetooth beacon, MAC beacon, rejestrowanie unikalnych adresów mac urządzeń, wyznaczanie algorytmiczne w oparciu o panujące natężenie ruchu na danej trasie. Wykonywane w oparciu o urządzenia zliczające pojazdy – VIP, pętle indukcyjne, techniki mikrofalowe i laserowe.
Prędkość w ruchu swobodnym (ang. <i>Free-flow speed</i>)	Prędkość w potoku ruchu w sytuacjach braku ograniczeń innymi czynnikami (z góry i doły). Gęstość i potok ruchu wynoszą zero.	Analizy prędkości w potoku ruchu dla danego odcinka. Wykorzystując urządzenia tematyki drogowej.
Odstęp (ang. <i>Headway h</i>)	Miara chwilowej odległości między dwoma pojazdami. Typowo wyznaczone w sekundach. Liczone od przodu pierwszego pojazdu do przodu następującego pojazdu.	Wyliczana jako odległość czasu pomiędzy zjawieniem się pierwszego pojazdu na punkcie kontrolnym do chwili pojawiania się pojazdu następującego. Z wykorzystaniem pętli - moment pierwszej zmiany w polu magnetycznym. Z wykorzystaniem monitoringu – obecność przedniego zderzaka w polu detekcji pierwszego pojazdu do przedniego zderzaka następującego pojazdu.
Odległość (ang. <i>Spacing</i>)	Fizyczna odległość między pojazdami wyznaczana w metrach. Jest powiązana z prędkością i odstępem.	Z wykorzystaniem monitoringu – obecność przedniego zderzaka w polu detekcji pierwszego pojazdu do przedniego zderzaka następującego pojazdu.
Luka (ang. <i>Gap</i>)	Miara chwilowej wolnej przestrzeni między pojazdami.	Wyliczana jako odległość czasu pomiędzy zjawieniem się pierwszego pojazdu na punkcie kontrolnym do chwili pojawiania się pojazdu następującego. Z wykorzystaniem pętli - kończący odczyt przejazdu (zmiany w polu magnetycznym). Z wykorzystaniem monitoringu – obecność tylnego zderzaka w polu detekcji pierwszego pojazdu do przedniego zderzaka następującego pojazdu.
Przeźroczliwość (ang. <i>Clearance c</i>)	Połączenie <i>gap</i> i <i>spacing</i> Miara odległości między pojazdami wyznaczone w metrach.	Wyznaczana na podstawie punktu kończącego pojazd (tylny zderzak) a początek następującego pojazdu (przedni zderzak).
Gęstość (ang. <i>Density</i>)	Liczba pojazdów na odcinek drogi dla jednego pasa ruchu.	Możliwe do wyznaczenia na zasadzie bramki dla danego odcinka.

Dodatek B

Parametry użyte do klasyfikacji

1	Spektrum
2	Cepstrum
3	Autokorelacja (waveform)
4	Peek position (waveform)
5	PeakMagMean (waveform)
6	RMS energii
7	Energia w niskim paśmie
8	Gęstość przejść przez zero
9	Rolloff
10	Rolloff (próg 0.5)
11	Jasność (powyżej 1500Hz)
12	Jasność (powyżej 4000Hz)
13-51	MFCC 1-39
52	Szorstkowość, wartość średnia
53	Szorstkowość, odchylenie standardowe
54	Szorstkowość, slope
55	Szorstkowość, entropia
56	Nieharmoniczność
57	Centroid widma
58	Rozrzut widma
59	Skrośność widma
60	Skrośność widma, pasma oktafowe, okno hamminga) [dB]
61	Kurtoza widma
62	Kurtoza widma (pasma oktafowe, okno hamminga) [dB]
63	Płaskość widma
64	Płaskość widma (pasma oktafowe, okno hamminga) [dB]
65	Entropia widma
66	Entropia widma (pasma oktafowe, okno hamminga) [dB]
67	Energia w niskim paśmie (ASR)

Dodatek C

Wyniki klasyfikacji typu pojazdu

Tabela C.1: NBC - Wyniki klasyfikacji, zbiór treningowy i zbiór testowy (60:40), wektor cech FV=67

	Zbiór treningowy					Zbiór testowy 40%			
	O	D	C	M		O	D	C	M
Osobowe	133	0	0	0	Osobowe	82	0	0	0
Dostawcze	27	14	11	0	Dostawcze	18	10	10	0
Ciężarowe	21	2	18	0	Ciężarowe	23	3	21	0
Motocykl	1	0	0	145	Motocykl	1	0	1	79
ACC	0,864	0,886	0,901	0,997	ACC	0,821	0,861	0,838	0,990
Precyzja	1,000	0,269	0,439	0,993	Precyzja	1,000	0,263	0,447	0,975
Czułość	0,731	0,875	0,621	1,000	Czułość	0,661	0,769	0,656	1,000
F-score	0,844	0,412	0,514	0,997	F-score	0,796	0,392	0,532	0,988

Tabela C.2: Wyniki klasyfikacji FLDA, zbiór treningowy i zbiór testowy (60:40), wektor cech FV=67

	Zbiór treningowy					Zbiór testowy			
	O	D	C	M		O	D	C	M
Osobowe	127	6	0	0	Osobowe	69	12	1	0
Dostawcze	7	43	0	0	Dostawcze	18	20	2	0
Ciężarowe	0	0	49	0	Ciężarowe	4	0	35	0
Motocykl	0	0	0	140	Motocykl	2	0	0	85
ACC	0,965	0,965	1,000	1,000	ACC	0,850	0,867	0,968	0,991
Precyzja	0,955	0,860	1,000	1,000	Precyzja	0,841	0,500	0,897	0,977
czułość	0,948	0,878	1,000	1,000	czułość	0,742	0,625	0,921	1,000
F-score	0,951	0,869	1,000	1,000	F-score	0,789	0,556	0,909	0,988

Tabela C.3: Trafność klasyfikacji (ACC) Naiwny klasyfikator Bayesa (FV=67, wyniki dla zbioru testowego 40%)

Numer serii treningu	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
1	0,823	0,866	0,905	0,995	0,897
2	0,833	0,901	0,877	0,971	0,896
3	0,861	0,880	0,899	0,990	0,908
4	0,853	0,905	0,913	1,000	0,918
5	0,840	0,891	0,895	1,000	0,906
Średnio dla klasyfikatora	0,842	0,888	0,898	0,991	0,905

Tabela C.4: Trafność klasyfikacji (ACC) Regresja liniowa (FV=26, wyniki dla zbioru testowego 40%)

Numer serii treningu	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
1	0,865	0,902	0,946	0,981	0,924
2	0,846	0,908	0,912	0,995	0,915
3	0,873	0,891	0,959	0,982	0,926
4	0,872	0,914	0,942	0,964	0,923
5	0,884	0,907	0,943	0,977	0,928
Średnio dla klasyfikatora	0,868	0,904	0,941	0,980	0,923

Tabela C.5: Trafność klasyfikacji (ACC) Regresja liniowa (FV=67, wyniki dla zbioru testowego 40%)

Numer serii treningu	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
1	0,866	0,899	0,960	0,991	0,929
2	0,854	0,917	0,925	0,991	0,922
3	0,871	0,889	0,977	1,000	0,934
4	0,887	0,913	0,969	0,991	0,940
5	0,895	0,910	0,982	1,000	0,947
średnio dla klasyfikatora	0,875	0,906	0,963	0,994	0,934

Tabela C.6: Jakość klasyfikacji (ACC) Regresja liniowa (FV=67, wyniki dla zbioru testowego 40%)

Numer serii treningu	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
1	0,877	0,913	0,945	0,988	0,931
2	0,871	0,905	0,922	0,983	0,920
3	0,847	0,879	0,940	0,987	0,913
4	0,893	0,924	0,927	0,976	0,930
5	0,885	0,905	0,926	0,980	0,924
Średnio dla klasyfikatora	0,875	0,905	0,932	0,983	0,924

Tabela C.7: Jakość klasyfikacji (ACC) Regresja liniowa (FV=67, 45% testowe)

Numer serii treningu	Osobowy	Dostawczy	Ciężarowy	Motocykl	Średnia dla próby
1	0,873	0,903	0,953	0,988	0,929
2	0,873	0,906	0,934	0,996	0,927
3	0,866	0,882	0,964	0,992	0,926
4	0,888	0,921	0,942	0,996	0,937
5	0,874	0,910	0,949	0,992	0,931
Średnio dla klasyfikatora	0,875	0,904	0,948	0,993	0,930

Tabela C.8: Wyniki najwyższych uzyskanych skuteczności dla FLDA. Kilka kilka podziałów zbiorów testowych dla całego i zredukowanego wektora parametrów (FV)

FLDA							
40,00%			Osobowy	Dostawczy	Ciężarowy	Motocykl	Całkowity
FV = 67	ACC		0,91	0,92	0,98	1,00	0,95
		F-score	0,87	0,75	0,92	0,99	0,88
	FV = 26	ACC	0,90	0,91	0,96	0,98	0,94
		F-score	0,84	0,73	0,87	0,97	0,85
45,00%			Osobowy	Dostawczy	Ciężarowy	Motocykl	Całkowity
FV = 67	ACC		0,89	0,91	0,96	0,99	0,94
		F-score	0,84	0,64	0,89	0,99	0,84
	FV = 26	ACC	0,90	0,91	0,96	0,98	0,94
		F-score	0,84	0,73	0,87	0,97	0,85
20,00%			Osobowy	Dostawczy	Ciężarowy	Motocykl	Całkowity
FV = 67	ACC		0,94	0,94	1,00	1,00	0,97
		F-score	0,92	0,77	1,00	1,00	0,92
	FV = 26	ACC	0,94	0,95	0,97	0,97	0,96
		F-score	0,92	0,81	0,87	0,97	0,89

Tabela C.9: Wpływ redukcji liczby parametrów na skuteczność klasyfikacji (20% danych testowych)

Długość FV	Parametr	Osobowy	Dostawczy	Ciężarowy	Motocykl	Całkowity
FV = 26	ACC	0,94	0,95	0,97	0,97	0,96
	F-score	0,92	0,81	0,87	0,97	0,89
FV = 22	ACC	0,91	0,92	0,97	1,00	0,95
	F-score	0,85	0,74	0,88	1,00	0,87
FV =17	ACC	0,90	0,92	0,96	0,99	0,94
	F-score	0,87	0,44	0,86	0,99	0,79
FV =12	ACC	0,87	0,92	0,90	0,97	0,87
	F-score	0,84	0,64	0,65	0,97	0,77

Dodatek D

Publikacje autorki

D.1 Dorobek Naukowy

Publikacje z listy JCR i rankingowane w bazach WoS i Scopus

1. Marciniuk K., Szczodrak M., Czyżweski A., *An application of acoustic sensors for the monitoring of road traffic*, Signal Processing - Algorithms, Architectures, Arrangements, and Applications Conference Proceedings, SPA Volume 2018-September, 4 December 2018, Pages 208-213
2. Marciniuk K., Blaszkę M., Kostek B., *Acoustic Road Monitoring*, MATEC Web of Conferences Volume 231, 16 November 2018, Article number 05002 12th International Road Safety Conference GAMBİT 2018 - "Road Innovations for Safety - The National and Regional Perspective", GAMBİT 2018; Gdansk University of Technology Gdansk; Poland; 12 April 2018 through 13 April 2018.
3. Kurowski A., Marciniuk K., Kostek B.: *Separability Assessment of Selected Types of Vehicle-Associated Noise* Multimedia and Network Information Systems/ : 2017, s.113-121.(best paper award)
4. Szczodrak M., Marciniuk K., Czyżewski A.: *Road surface roughness estimation employing integrated position and acceleration sensor*, Signal Processing - Algorithms, Architectures, Arrangements, and Applications Conference Proceedings, SPA Volume 2017-September, 4 December 2017, Article number 8166869, Pages 228-232
5. Marciniuk K., Kostek B., Czyżewski A., *Traffic Noise Analysis Applied to Automatic Vehicle Counting and Classification*, Communications in Computer and Information Science Volume 785, 2017, Pages 110-123.
6. Marciniuk K., Szczodrak M., Kostek B.: *Performance of Noise Map Service Working in Cloud Computing Environment* Archives of Acoustics. -Vol. 41, iss. 2 (2016), s.297-302

-
- Marciniuk K., Kostek B.: *Creating a numerical model of noise conditions based on the analysis of traffic volume changes in cities with low and medium structure*, Archives of Acoustics. -Vol. 40, nr. 3 (2015), s.438-439

D.2 Inne publikacje konferencyjne, monografie i książki związane z tematyką rozprawy

- Marciniuk K., Kostek B.: *Sound quality metrics applied to road noise evaluation*. The Journal of the Acoustical Society of America 144.3 (2018): 1930-1931.
- Marciniuk K., Kostek B.: *Influence of Data Normalization on the Effectiveness of Neural Network Applied to Classification of Pavement Conditions - Case Study*, Zeszyty Naukowe Wydziału ETI Politechniki Gdańskiej, Technologie Informacyjne, Vol. 23, Issue: 1, ISSN: 1732-1166, 2018.
- Marciniuk K., Kostek B., Czyżewski A., *Classifying type of vehicles on the basis of data extracted from audio signal characteristic*, The Journal of the Acoustical Society of America, Vol. 141, No. 5, Pt. 2 of 2, May 2017.
- Marciniuk K., Kurowski A.: *Zastosowanie sensorów akustycznych do automatycznej klasyfikacji stanu nawierzchni*, X Polski Kongres ITS, 16-17 maja 2017, Warszawa.
- Marciniuk K., Kostek B.: *Analiza stanu nawierzchni i klas pojazdów na podstawie parametrów ekstrahowanych z sygnału fonicznego*. , Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej (2016).
- Marciniuk K., Kurowski A., Kostek B.: *Analiza sygnałów fonicznych w nagraniach pojazdów w zmiennych warunkach pogodowych* , Współczesne zagadnienia techniki fonicznej, wizyjnej i medycznej ed. Andrzej Dobrucki, Maurycy J. Kin, Lucyna Leniowska, Wrocław - Rzeszów 2016, s.139-149, (best paper award)
- Marciniuk K., Kostek B.: *Analiza stanu nawierzchni i klas pojazdów na podstawie parametrów ekstrahowanych z sygnału fonicznego*, Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej. -, nr. 51 (2016), s.115-118
- Czyżewski A., Marciniuk K., Kostek B., *Dynamic road traffic density estimation employing noise mapping with the use of grid supercomputing*. The Journal of the Acoustical Society of America 139.4 (2016): 2006-2006.
- Marciniuk K., Szczodrak M., Kostek B.: *Wyznaczanie map hałasu z wykorzystaniem chmury obliczeniowej*, XVI Międzynarodowe Sympozjum Inżynierii i Reżyserii Dźwięku ISSET'2015, ed. Zbigniew Kulka, Marcin Lewandowski

Warszawa: Fundacja Wspierania Rozwoju Radiokomunikacji i Technik Multimediaalnych, 2015, s.36-43

10. Kotus J., Szczodrak M., Marciniuk K., Czyżewski A., Kostek B.: *Creating Dynamic Psychoacoustic Maps of Hearing Threats for Outdoor Concerts Employing Supercomputing Grid*, 136th International AES Convention. (2014),

Nagrody, wyróżnienia

1. III miejsce w konkursie im. doktora Ryszarda Krystka za najlepszą prezentację podczas XI międzynarodowej konferencji GAMBIT w Gdańsku. Karolina Marciniuk, doktorantka Laboratorium Akustyki Fonicznej WETI PG, uzyskała trzecią nagrodę w konkursie im. Profesora Ryszarda Krystka za najlepszą prezentację w Sesji Młodych Naukowców. Tematem prezentacji był Akustyczny monitoring ruchu drogowego, przygotowywany wspólnie z Maciejem Blaszką i prof. Bożeną Kostek. Konkurs przeprowadzony został podczas 12. Międzynarodowej Konferencji Bezpieczeństwa Ruchu Drogowego GAMBIT 2018 w dniach 12-13 kwietnia na Politechnice Gdańskiej.
2. Best Paper w kategorii *Traffic Monitoring* za wygłoszenie referatu *Traffic Noise Analysis Applied to Automatic Vehicle Counting and Classification* przygotowanego wspólnie z prof. Bożeną Kostek i prof. Andrzejem Czyżewskim na IX Międzynarodowej Konferencji IEEE Multimedia Communications Services and Security (IEEE MCSS) w dniach 16-17 listopada 2017 r. w Krakowie.
3. Best Paper Award na konferencji MISSI 2016 Referat zespołu w składzie: prof. dr hab. inż. Bożena Kostek, mgr inż. Adam Kurowski oraz mgr inż. Karolina Marciniuk, wygłoszony na konferencji MISSI 2016 - The 10th edition of International Conference on Multimedia & Network Information Systems, Wrocław (14-16.09.2016), zatytułowany Separability Assessment of Selected Types of Vehicle-Associated Noise, otrzymał nagrodę The Best Paper Award.

D.3 Patenty, granty i działalność wspierająca naukę

Autorka pracy jest laureatką grantu Harman Scholar 2017 przyznawanego przez Audio Engineering Society Educational Foundation. W latach 2015-2018 pełniła funkcję Opiekuna Koła Naukowego Inżynierii Dźwięku i Obrazu. Jest członkiem międzynarodowego stowarzyszenia Audio Engineering Society (AES) oraz Polskiego Towarzystwa Akustycznego (PTA) związanego z European Acoustics Association (EAA). Od 2014 roku pełni funkcje opiekuna Koła Naukowego Inżynierii Dźwięku i Obrazu.

Spis rysunków

1.1	Schematyczne ujęcie tematyki i struktury pracy, z opisem zawartości poszczególnych rozdziałów	22
1.2	Algorytmiczny schemat działania typowych systemów ML	23
2.1	Model empiryczny (po lewej) i model obliczeniowy równania ruchu [34]	29
2.2	Wpływ warunków geometrycznych drogi na klasę drogi i dopuszczalne na niej prędkości (źródło: Google Maps)	30
2.3	Przykłady wykresu histogramu, gęstości prawdopodobieństwa i dystrybuanty, rozkład normalny [66]	31
2.4	Wykres zależności prędkości pojazdu w potoku ruchu od gęstości pokazujący granice przepustowości drogi	31
2.5	Widoczne cięcia po wprowadzeniu pętli indukcyjnych (para na każdy pas ruchu - (po lewej) wraz z wyprowadzeniem połączeń fiderem prowadzącym sygnały do detektora, urządzenia VIP wraz z oświetlaczem (po prawej)	35
2.6	Zjawisko przesłaniania większego pojazdu przez drugi powodujące błędy w pomiarach w zliczaniu pojazdów w systemach instalowanych przy drogach	36
2.7	Różne sytuacje drogowe uchwycone przez kamery drogowe (źródło: dailymail.co.uk, oraz kamery GDDKiA)	37
2.8	Efektywność wczesnych systemów VIP, badania przeprowadzone w 1998 roku przez Kalifornijski Instytut Technologii w Pasadenie) .	37
2.9	Podstawowe parametry i zasady konfiguracji urządzeń LiDARowych	38
2.10	Obrazowanie 3-D pojazdu z przyczepą (Zdjęcie z zasobów Schwartz Electro-Optics, now OSI Laserscan, Orlando, FL)	39
2.11	Terytorialny podział ruchu [66]	42
2.12	Koncepcyjny schemat podsystemów zarządzania ruchem w systemie TRISTAR [55]	44

2.13	Ilustracja danych z detektorów indukcyjnych z sytemu TRISTAR (dzięki uprzejmości ZDiZ Gdańsk)	45
3.1	Parametry dynamiczne i stałe wpływające na wynikowy dźwięk generowany przez pojazd w ruchu	48
3.2	Rozkład źródeł poszczególnych hałasów w przypadku poruszającego się pojazdu[9, 127]	49
3.3	Proces generowania dźwięku toczenia: A - zetknięcie opony z podłożem, B - wibracje powietrza między żłobieniami bieżnika, C - wibracje przekazywane przed oponę do podłoża (grafika pochodzi ze strony michelintransport.com)	49
3.4	Schemat badania poziomego hałasu emisji układu wydechowego wg. normy PN-92/5-04051-3[109]	51
3.5	Poszczególne warstwy mapy hałasu miasta Gdańsk [138]	53
4.1	Schemat działania systemów rozpoznawania otoczenia	56
4.2	Rozkład grup parametrów dźwięku, bazując na standardzie MPEG-7[74]	58
4.3	Parametr ZCR zlicza momenty, w których amplituda sygnału zmienia znak	62
4.4	Rozkłady skośności sygnału $D(x)$ względem wartości średniej \bar{x} i mediany $Me(x)$ [91]	63
4.5	Zobrazowanie parametru <i>brightness</i> [69]	64
4.6	Zobrazowanie parametru <i>low energy</i> [69]	65
4.7	Schemat wyznaczania parametrów mel-cepstralnych	65
4.8	10 filtrów melowych pokrywających pasmo od 0-8 kHz	66
4.9	Spektrum sygnału i wartość miary szorstkości brzmienia [115],	68
4.10	Przykładowe spektrogramy: po lewej - przejazd karetki pogotowia przy dużym zagęszczeniu ruchu; po prawej - indywidualny przejazd pojazdu osobowego przy małym natężeniu ruchu	69
4.11	Odpowiedzi filtrów gammatone	70
4.12	Wynik operacji gammatone dla przejazdu pojazdu z niskoczęstotliwościowym zakłóceniem	71
4.13	Klasyfikacja systemów uczenia maszynowego	73
4.14	Wizualizacja działania wybranych metod uczenia maszynowego w kontekście separowalności klas za pomocą wykresu rozrzutu [141]	74
4.15	Ilustracja klasyfikatora SVM i miar go opisujących [129]	76



4.16	Prosty schemat sieci neuronowej z p wejściami X , jedną warstwą oraz K -elementowym wektorem wyjściowym [141]	78
4.17	Porównanie dostępnych rodzajów sieci neuronowych – prosta sieć, z jedną warstwą ukrytą, głęboka sieć zawierająca typowo kilka do kilkunastu warstw ukrytych oraz sieci splotowe stosowane typowo w systemach rozpoznawania obrazu [141]	78
4.18	Podział zbioru próbek na dwie hiperpłaszczyzny zapewniające optymalny wynik klasyfikatora	83
4.19	Wykresy rozrzutu z przykładowymi wartościami i kierunkami korelacji liniowej [91]	84
5.1	Uproszczony diagram działania klasyfikacji zdarzeń w ruchu drogowym	89
5.2	Schemat pomiarowy	89
5.3	Akwizycja danych pomiarowych, rejestrator z kamerą wideo (po lewej) oraz radarowy rejestrator ruchu dzięki uprzejmości GDDKiA (po prawej)	90
5.4	Uproszczony diagram działania detekcji obecności pojazdów	92
5.5	Typowy schemat systemu polegający na detekcji aktywności w sygnale	93
5.6	Wyniki śledzenia aktywności w sygnale dla kilku parametrów	94
5.7	Tygodniowy rozkład hałasu L_{A1Heq} rejestrowany na jednej z większych ulic Gdańska - Łostowicka.	95
5.8	Wyniki wykrywania dla pojazdów w przypadku braku zastosowania adaptacji progu reakcji, ramka 500 ms, zakładkowanie 25%	96
5.9	Wyniki wykrywania dla pojazdów w przypadku braku zastosowania adaptacji progu reakcji, ramka 500 ms, zakładkowanie 25%	97
5.10	Zliczanie pojazdów na podstawie generowanego sygnału z zastosowaniem progu detekcji z adaptacją	98
5.11	Zliczanie pojazdów na podstawie generowanego sygnału z zastosowaniem progu detekcji z adaptacją	98
5.12	Wyniki zliczania trzema. Uzyskane wykrycia w funkcji czasu.	100
5.13	Wyniki zliczania trzema metodami pomiaru wraz z danymi odniesienia	101
5.14	Różnice między klasami pojazdów w kontekście zawartości widmowej (po lewej), efektem LDA dla dwóch wybranych klas pojazdów z danymi nieprzypisanymi do żadnej klasy pojazdów, powodującymi nakładanie się w grupach (po prawej).	102
5.15	Wpływ długości wektora cech na jakość klasyfikacji ACC dla FLDA	108

5.16 Wyniki trójwymiarowego wykresu rozrzutu dla obserwowanych zmian w stanie nawierzchni	112
5.17 Funkcja a) binary step i b) tangens hiperboliczny	113
5.18 Schemat sieci i połączeń przy analizie stanu nawierzchni	114

Spis tabel

2.1	Prawne, psychologiczne i fizyczne czynniki decydujące o prędkościach osiągniętych na drogach [34]	28
2.2	Systematyka dostępnych urządzeń telematyki drogowej służących do detekcji pojazdów i ustalania parametrów ruchu [45]	34
2.3	Zalety i wady stosowania czujników optycznych [45]	39
2.4	Zalety i wady stosowania czujników optycznych VIP [45]	40
3.1	Uwarunkowania związane z wartością współczynnika przyczepności .	50
4.1	Przegląd dotychczasowych badań w dziedzinie rozpoznawania dźwięków pojazdów	60
4.2	Podział różnych rodzajów uczenia maszynowego (ML) w akustyce z podziałem na ich zastosowanie i wynik działania	71
4.3	Wartości siły korelacji w zależności od uzyskanego współczynnika .	84
4.4	Tablica pomyłek stosowana przy ocenie systemów klasyfikacyjnych w kontekście rozróżniania dwóch klas	85
5.1	Wyniki analizy parametrów detekcji aktywności w sygnale i wyznaczone liczby pojazdów dla okna analizy 5 min. Skuteczność detekcji wyznaczana jest za pomocą wzoru 4.47 (1. pojazdów w analizowanym fragmencie 135, zakładkowanie 50%, adaptacja progu detekcji 2 s) .	99
5.2	Liczba wyznaczonych pojazdów na podstawie trzech metod - Doppler TMS-SA (koszt ok 6 tys.), LiDAR (koszt ok. 120 000 zł), opracowywana metoda akustyczna oraz dane ze zliczania ręcznego na podstawie strumienia wideo	101
5.3	Trafność klasyfikacji (ACC) Naiwny klasyfikator Bayesa (liczba parametrów: FV=67, wyniki dla zbioru testowego 40%)	103
5.4	Najlepsza uzyskana skuteczność dla klasyfikatora NBC przy analizie typu pojazdu (zbiór treningowy 60%)	103



5.5	Najlepsza uzyskana skuteczność dla klasyfikatora NBC przy analizie typu pojazdu (zbiór testowy 40%)	103
5.6	Trafność klasyfikacji (ACC) Liniowa analiza dyskryminacyjna-Fishera(FV=67, 40% zbioru testowego)	104
5.7	Najlepsza uzyskana skuteczność dla klasyfikatora FLDA przy analizie typu pojazdu (zbiór treningowy 60%)	104
5.8	Najlepsza uzyskana skuteczność dla klasyfikatora FLDA przy analizie typu pojazdu (zbiór testowy 40%)	104
5.9	Trafność klasyfikacji (ACC) Regresja liniowa (FV=67, 40% zbioru testowego)	105
5.10	Najlepsza uzyskana skuteczność dla klasyfikatora REG przy analizie typu pojazdu (zbiór treningowy 60%)	105
5.11	Najlepsza uzyskana skuteczność dla klasyfikatora REG przy analizie typu pojazdu (zbiór testowy 40%)	105
5.12	Trafność klasyfikacji (ACC) PLS - Częściowa regresja średniokwadratowa (FV=67, 40% zbioru testowego)	106
5.13	Najlepsza uzyskana skuteczność dla klasyfikatora PLA przy analizie typu pojazdu (zbiór treningowy 60%)	106
5.14	Najlepsza uzyskana skuteczność dla klasyfikatora PLA przy analizie typu pojazdu (zbiór testowy 40%)	106
5.15	Trafność klasyfikacji (ACC) LDA - Częściowa regresja średniokwadratowa (FV=67, 40% zbioru testowego)	107
5.16	Najlepsza uzyskana skuteczność dla klasyfikatora LDA przy analizie typu pojazdu (zbiór treningowy 60%)	107
5.17	Najlepsza uzyskana skuteczność dla klasyfikatora LDA przy analizie typu pojazdu (zbiór testowy 40%)	107
5.18	Wyniki klasyfikacji dla zbiorów testowych (40%) przeprowadzonych dla wybranych klasyfikatorów	107
5.20	Najlepsza uzyskana skuteczność dla klasyfikatora FLDA przy analizie typu pojazdu, zredukowana liczba parametrów (40% - zbiór testowy)	109
5.19	Najlepsza uzyskana skuteczność dla klasyfikatora FLDA przy analizie typu pojazdu, zredukowana liczba parametrów (60% - zbiór treningowy)	109
5.21	Spis parametrów składających się na najkrótszy wektor cech	109
5.22	Rozróżnienie stanu nawierzchni zgodnie z Normą PN-EN 1555178-3:2011	110
5.23	Wyniki analizy dla parametru <i>brightness</i> w różnych konfiguracjach	111



5.24	Parametr Low-energy i jego wpływ na rozróżnianie stanu nawierzchni	111
5.25	Naiwny klasyfikator Bayesa 40% zbioru testowego. Macierz błędów i ocena skuteczności	112
5.26	Liniowa analiza dyskryminacyjna Fishera 40% zbioru testowego. Macierz błędów i ocena skuteczności	112
5.27	Wektor odpowiedzi klasyfikatora dla warunków meteorologicznych	113
5.28	Wyniki rozpoznawania warunków pogodowych z wykorzystaniem sieci neuronowej i zredukowanego za pomocą metody PCA zestawu parametrów (FV=12). Normalizacja min-max.	113
A.1	Parametry ruchu, ich funkcjonalność i metody pomiaru	133
C.1	NBC - Wyniki klasyfikacji, zbiór treningowy i zbiór testowy (60:40), wektor cech FV=67	137
C.2	Wyniki klasyfikacji FLDA, zbiór treningowy i zbiór testowy (60:40), wektor cech FV=67	137
C.3	Trafność klasyfikacji (ACC) Naiwny klasyfikator Bayesa (FV=67, wyniki dla zbioru testowego 40%)	138
C.4	Trafność klasyfikacji (ACC) Regresja liniowa (FV=26, wyniki dla zbioru testowego 40%)	138
C.5	Trafność klasyfikacji (ACC) Regresja liniowa (FV=67, wyniki dla zbioru testowego 40%)	138
C.6	Jakość klasyfikacji (ACC) Regresja liniowa (FV=67, wyniki dla zbioru testowego 40%)	139
C.7	Jakość klasyfikacji (ACC) Regresja liniowa (FV=67, 45% testowe)	139
C.8	Wyniki najwyższych uzyskanych skuteczności dla FLDA. Kilka kilka podziałów zbiorów testowych dla całego i zredukowanego wektora parametrów (FV)	139
C.9	Wpływ redukcji liczby parametrów na skuteczność klasyfikacji (20% danych testowych)	140