



**POLITECHNIKA
GDAŃSKA**

Imię i nazwisko autora rozprawy: Andrzej Sroczyński
Dyscyplina naukowa: Informatyka techniczna I telekomunikacja

ROZPRAWA DOKTORSKA

Tytuł rozprawy w języku polskim: Adaptacyjny system sterowania ruchem drogowym

Tytuł rozprawy w języku angielskim: Adaptive traffic control system

Promotor <i>podpis</i>	Drugi promotor <i>podpis</i>
Prof. dr hab. inż. Andrzej Czyżewski	
Promotor pomocniczy <i>podpis</i>	Kopromotor <i>podpis</i>
Dr inż. Piotr Ody	

Gdańsk, rok 2023



POLITECHNIKA
GDAŃSKA

DOKTORAT WDROŻENIOWY

Program Ministerstwa Nauki
i Szkolnictwa Wyższego

Gdańsk, rok 2023



OŚWIADCZENIE

Autor rozprawy doktorskiej: Andrzej Sroczyński

Ja, niżej podpisany(a), oświadczam, iż jestem świadomy(a), że zgodnie z przepisem art. 27 ust. 1 i 2 ustawy z dnia 4 lutego 1994 r. o prawie autorskim i prawach pokrewnych (t.j. Dz.U. z 2021 poz. 1062), uczelnia może korzystać z mojej rozprawy doktorskiej zatytułowanej:

Adaptacyjny system sterowania ruchem drogowym
do prowadzenia badań naukowych lub w celach dydaktycznych.¹

Świadomy(a) odpowiedzialności karnej z tytułu naruszenia przepisów ustawy z dnia 4 lutego 1994 r. o prawie autorskim i prawach pokrewnych i konsekwencji dyscyplinarnych określonych w ustawie Prawo o szkolnictwie wyższym i nauce (Dz.U.2021.478 t.j.), a także odpowiedzialności cywilnoprawnej oświadczam, że przedkładana rozprawa doktorska została napisana przeze mnie samodzielnie.

Oświadczam, że treść rozprawy opracowana została na podstawie wyników badań prowadzonych pod kierunkiem i w ścisłej współpracy z promotorem prof. dr hab. inż. Andrzejem Czyżewskim, promotorem pomocniczym dr inż. Piotrem Odyą.

Niniejsza rozprawa doktorska nie była wcześniej podstawą żadnej innej urzędowej procedury związanej z nadaniem stopnia doktora.

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

Potwierdzam zgodność niniejszej wersji pracy doktorskiej z załączoną wersją elektroniczną.

Gdańsk, dnia 31 sierpnia 2023 r.

.....
podpis doktoranta

Ja, niżej podpisany(a), wyrażam zgodę/nie wyrażam zgody* na umieszczenie ww. rozprawy doktorskiej w wersji elektronicznej w otwartym, cyfrowym repozytorium instytucjonalnym Politechniki Gdańskiej.

Gdańsk, dnia 31 sierpnia 2023 r.

.....
podpis doktoranta

¹ Art. 27. 1. Instytucje oświatowe oraz podmioty, o których mowa w art. 7 ust. 1 pkt 1, 2 i 4–8 ustawy z dnia 20 lipca 2018 r. – Prawo o szkolnictwie wyższym i nauce, mogą na potrzeby zilustrowania treści przekazywanych w celach dydaktycznych lub w celu prowadzenia działalności naukowej korzystać z rozpowszechnionych utworów w oryginale i w tłumaczeniu oraz zwielokrotnić w tym celu rozpowszechnione drobne utwory lub fragmenty większych utworów.

2. W przypadku publicznego udostępniania utworów w taki sposób, aby każdy mógł mieć do nich dostęp w miejscu i czasie przez siebie wybranym korzystanie, o którym mowa w ust. 1, jest dozwolone wyłącznie dla ograniczonego kręgu osób uczących się, nauczających lub prowadzących badania naukowe, zidentyfikowanych przez podmioty wymienione w ust. 1.





OPIS ROZPRAWY DOKTORSKIEJ

Autor rozprawy doktorskiej: Andrzej Sroczyński

Tytuł rozprawy doktorskiej w języku polskim: Adaptacyjny system sterowania ruchem drogowym

Tytuł rozprawy w języku angielskim: Adaptive traffic control system

Język rozprawy doktorskiej: polski

Promotor rozprawy doktorskiej: Prof. dr hab. inż. Andrzej Czyżewski

Drugi promotor rozprawy doktorskiej*: <imię, nazwisko>

Promotor pomocniczy rozprawy doktorskiej* : Dr inż. Piotr Ody

Kopromotor rozprawy doktorskiej*: <imię, nazwisko>

Data obrony:

Słowa kluczowe rozprawy doktorskiej w języku polskim: inteligentne systemy transportowe, znaki zmiennej treści, rekurencyjne sieci neuronowe.

Streszczenie rozprawy w języku polskim:

Adaptacyjny system sterowania ruchem drogowym to rodzaj systemu sterowania, który dynamicznie, w czasie rzeczywistym, dostosowuje swoje parametry w oparciu o bieżące warunki ruchu drogowego. Celem niniejszej rozprawy jest sprawdzenie wpływu wybranych cech systemu, zbudowanego w oparciu o zaprojektowane i zbudowane z udziałem autora inteligentne znaki drogowe, na wybrane parametry mające wpływ na bezpieczeństwo i płynność ruchu. W pierwszej kolejności zbadany został, na podstawie eksperymentu symulacyjnego, wpływ metody stopniowania redukcji prędkości na płynność ruchu. Drugim przedmiotem badań był wpływ odległości pomiędzy kolejnymi znakami ograniczenia prędkości na wariancję prędkości pojazdów. Ostatnim badanym aspektem była weryfikacja możliwości testowania modeli uczenia maszynowego, wytrenowanych na danych rzeczywistych, za pomocą danych syntetycznych, uzyskanych w drodze symulacji. Wyniki badań posłużyły do udowodnienia trzech tez badawczych, sformułowanych w niniejszej pracy. Praca zawiera ponadto rozdział w całości poświęcony opisowi praktycznej realizacji demonstratora adaptacyjnego systemu sterowania ruchem drogowym. Przedstawione zostały instalacje eksperymentalne oraz niektóre rezultaty badań terenowych, zaś dodatkiem do rozprawy jest przegląd konstrukcji opracowanych demonstratorów inteligentnych znaków drogowych.

* *niepotrzebne skreślić*





Streszczenie rozprawy w języku angielskim:

An adaptive traffic control system is a type of control system that dynamically, in real time, adjusts its parameters based on current traffic conditions. This dissertation aims to test the influence of selected features of the system, built on the basis of intelligent traffic signs designed and built with the author's participation, on selected parameters affecting traffic safety and fluidity. Firstly, the effect of the speed reduction grading method on traffic flow was investigated, based on a simulation experiment. The second subject studied was the effect of the distance between successive speed reduction signs on the variance of vehicle speeds. The final aspect investigated was the verification of the possibility of testing machine learning models, trained on real data, with synthetic data obtained through simulation. The results were used to prove the three research theses formulated in this thesis. In addition, the thesis contains a chapter entirely devoted to the description of the practical implementation of an adaptive traffic control system demonstrator. Experimental installations and some results of field tests are presented, while an appendix to the thesis is a review of the design of the developed smart traffic sign demonstrators.

Podziękowania

Dziękuję mojemu Promotorowi, Profesorowi Andrzejowi Czyżewskiemu, za opiekę merytoryczną.

Dziękuję Opiekunowi Pomocniczemu, Prezesowi Zarządu firmy TSTRONIC Sp. z o.o., mgr inż. Radosławowi Mioduskiemu za stworzenie warunków do realizacji pracy doktorskiej.

Dziękuję serdecznie mojej żonie, Bożenie, która wykazała niezwykłą cierpliwość i wyrozumiałość w czasie mojego zaangażowania w pracę nad niniejszą rozprawą.

Spis oznaczeń i skrótów

AASHTO	American Association of State Highway and Transportation Officials
ARIMA	Autoregressive integrated moving average
BiLSTM	Bidirectional LSTM
Caltrans	California Department of Transportation
DCRNN	Diffusion Convolutional Recurrent Neural Network
DNN	Deep Neural Network
GHR	Gazis–Herman–Rothery model
GMN	Graph-Markov-Network
GRU	Gated Recurrent Unit
HMI	Human-Machine Interface
IDM	Intelligent Driver Model
IDZ	Inteligentny Znak Drogowy
ITS	Intelligent Transportation System
LSTM	Long short-term memory
M2M	Machine-to-Machine
MAE	Mean Absolute Error
MAPE	Mean Absolute Percent Error
MDP	Mikrofalowy Detektor Pojazdów
MSE	Mean Squared Error
NaSch	Nagel-Schreckenberg model
OVN	Optimal Velocity model
PeMS	Performance Measurement System
RMSE	Rooted Mean Squared Error
SAE	Stacked Auto-Encoder
SARIMA	Seasonal Autoregressive Integrated Moving Average
SGMN	Spectral Graph Markov Network
T-LSTM	Time Aware LSTM
V2X	Vehicle-to-everything
W-74	model 74 Wiedemanna
W-99	model 99 Wiedemanna
WSA	Wektorowa Sonda Akustyczna

Spis rysunków

Rys. 1. Psychofizyczny model typu car-following.	15
Rys. 2. Progi percepcji modelu Wiedemanna	24
Rys. 3. Progi percepcji i stany modelu Fritzscha	27
Rys. 4. Model odcinków dróg przyjęty w symulacji czasu przejazdu	36
Rys. 5. Znormalizowany czas podróży w zależności od natężenia ruchu i odległości znaków drogowych.	38
Rys. 6. Sieć drogowa odpowiadająca scenariuszowi przeprowadzonych symulacji.....	39
Rys. 7. Lokalizacja znaków ograniczenia prędkości i punktów pomiarowych.	40
Rys. 8. Prędkości pojazdów dla dystansu $d = 75$ m.....	43
Rys. 9. Prędkości pojazdów dla dystansu $d = 100$ m.....	44
Rys. 10. Prędkości pojazdów dla dystansu $d=150$ m.....	44
Rys. 11. Rozkład prędkości pojazdów w punkcie pomiarowym MP5 i odległości $d=75$ m.	45
Rys. 12. Rozkład prędkości pojazdów w punkcie pomiarowym MP6 dla dystansu $d=75$ m.	45
Rys. 13. Rozkład prędkości pojazdów w punkcie pomiarowym MP7 dla dystansu $d=75$ m.	46
Rys. 14. Rozkład prędkości pojazdów w punkcie pomiarowym MP5 i odległości $d=100$ m.	46
Rys. 15. Rozkład prędkości pojazdów w punkcie pomiarowym MP6 i odległości $d=100$ m.	47
Rys. 16. Rozkład prędkości pojazdów w punkcie pomiarowym MP7 i odległości $d=100$ m.	47
Rys. 17. Rozkład prędkości pojazdów w punkcie pomiarowym MP5 i odległości $d=150$ m.	48
Rys. 18. Rozkład prędkości pojazdów w punkcie pomiarowym MP6 i odległości $d=150$ m.	48
Rys. 19. Rozkład prędkości pojazdów w punkcie pomiarowym MP7 i odległości $d=150$ m.	49
Rys. 20. Wariancja prędkości na łuku drogi, przypadek suchej nawierzchni.	49
Rys. 21. Wariancja prędkości pojazdu dla dystansu d równego 75 m, 100 m, 150 m (przypadek śliskiej nawierzchni).	50
Rys. 22. Model LSTM.....	52
Rys. 23. Model GRU.....	52
Rys. 24. Model SAE.....	53
Rys. 25. Średni błąd procentowy między wartościami przewidywanymi	



a rzeczywistymi dla zestawu walidacyjnego czterech modeli LSTM: jedno-, dwu-, trzy- i czterowarstwowego.	55
Rys. 26. Średni błąd procentowy między wartościami przewidywanymi a rzeczywistymi dla zestawu walidacyjnego czterech modeli GRU: jedno-, dwu-, trzy- i czterowarstwowego.....	55
Rys. 27. Średni błąd procentowy między wartością przewidywaną a rzeczywistą dla zestawu walidacyjnego modelu SAE i czterowarstwowymi modelami GRU i LSTM.	56
Rys. 28. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 1-warstwowe LSTM i GRU dla 5-dniowego przedziału czasowego	57
Rys. 29. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 2-warstwowe LSTM i GRU dla 5-dniowego przedziału czasowego.....	58
Rys. 30. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 3-warstwowe LSTM i GRU dla 5 - dniowego przedziału czasowego.....	58
Rys. 31. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 4-warstwowe LSTM i GRU dla 5 - dniowego przedziału czasowego.....	59
Rys. 32. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 3-warstwowe LSTM i GRU dla 24-godzinnego przedziału czasowego.....	60
Rys. 33. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 3-warstwowe LSTM i GRU dla 8-godzinnego przedziału czasowego.....	60
Rys. 34. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 4-warstwowe LSTM i GRU dla 24-godzinnego przedziału czasowego.....	61
Rys. 35. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 4-warstwowe LSTM i GRU dla 8-godzinnego przedziału czasowego.....	61
Rys. 36. Idea pracy inteligentnego znaku drogowego.....	64
Rys. 37. Klasyfikacja pojazdów na podstawie nagrania wideo z algorytmem odejmowania tła (rys. (a)) oraz z zastosowaniem sieci neuronowej (rys. (b)).....	65
Rys. 38. Obraz z kamery termowizyjnej oraz RGB.	66
Rys. 39. Przykład neuronowego transferu stylu.....	66
Rys. 40. Ilustracja metody oceny stanu nawierzchni jezdni za pomocą analizy obrazu i CNN.....	67
Rys. 41. Model 3D wektorowej sondy akustycznej.....	67
Rys. 42. Budowa czujnika akustycznego WSA.....	68
Rys. 43. Uproszczony schemat blokowy wektorowej sondy akustycznej.....	68
Rys. 44. Czujnik akustyczny WSA w obudowie.....	69
Rys. 45. Mikrofalowy czujnik radarowy RSM2650.	69
Rys. 46. Spektrogram sygnału zarejestrowanego z czujnika dopplerowskiego (przejazdy samochodów). Oś pozioma: indeks ramki analizy, oś pionowa: prędkość w km/h. ...	70
Rys. 47. Wyniki analizy danych z Rys. 46. Oś pozioma: indeks ramki analizy, oś pionowa: prędkość w km/h.....	70

Rys. 48. Liczba pojazdów na godzinę i średnia prędkość pojazdów na godzinę, dla czujnika dopplerowskiego (kolor niebieski) i dla Metrocount (kolor pomarańczowy).	71
Rys. 49. Panel wyświetlacza IZD, rozdzielczość 8 x 8 pikseli RGB.....	71
Rys. 50. Elementy łączące panele wyświetlacza.....	72
Rys. 51. Schemat blokowy system łączności.....	72
Rys. 52. Struktura komunikacji systemowej.....	74
Rys. 53. Schemat blokowy modelu badawczego inteligentnego znaku drogowego.	75
Rys. 54. Wnętrze szafy pomiarowej z zamontowanymi podzespołami.....	76
Rys. 55. Szafa pomiarowa z czujnikami zewnętrznymi, widoczny sposób doprowadzenia zasilania.	76
Rys. 56. Miejsce instalacji szafy badaniowej - widok od strony jezdni, ul. Traugutta.	77
Rys. 57. Położenie punktu pomiarowego. Odległość punktu od drogi S7 585 m.....	77
Rys. 58. Proces instalowania urządzenia pomiarowego. U dołu szafka zasilająca. Lokalizacja Leźno, Aleja Lipowa	78
Rys. 59. Wnętrze urządzenia pomiarowego. Lokalizacja Leźno, Aleja Lipowa.	78
Rys. 60. Moduł pomiarowy w trakcie montażu przy drodze S7.....	79
Rys. 61. Dane statystyczne uzyskane w instalacji w Leźnie na podstawie detekcji pojazdów i pomiaru ich prędkości z użyciem czujnika radarowego, wygenerowane przez system Grafana.....	80
Rys. 62. Prototypowa instalacja systemu zasilania inteligentnego znaku.	81
Rys. 63. Schemat blokowy układu pomiarowego do testowania wydajności energetycznej turbiny wiatrowej oraz panelu solarnego.	81
Rys. 64. Profil dzienny energii słonecznej [Wh].	82
Rys. 65. Profil dzienny energii wiatrowej [Wh].....	82
Rys. 66. Profil dzienny energii łącznej [Wh].	83
Rys. 67. Pomiary terenowe w siedzibie firmy Microsystem, ul. Nowy Świat, Gdańsk.	84
Rys. 68. Zrealizowane wersje inteligentnego znaku drogowego.....	85

Spis Tabel

Tabela 1. Metryki błędów predykcji przedstawionej na rys. 28.....	57
Tabela 2. Metryki błędów predykcji przedstawionej na rys. 29.....	58
Tabela 3. Metryki błędów predykcji przedstawionej na rys. 30.....	59
Tabela 4. Metryki błędów predykcji przedstawionej na rys. 31.....	59

Spis treści

Spis oznaczeń i skrótów	1
Spis rysunków.....	2
Spis Tabel	5
Rozdział 1.....	8
Wprowadzenie.....	8
1.1 Geneza i cel pracy	10
1.2 Zawartość rozprawy	12
Rozdział 2.....	13
Modelowanie ruchu drogowego.....	13
2.1 Matematyczne modele zachowań kierowców	13
2.2 Techniki uczenia maszynowego w Inteligentnych Systemach Transportowych	28
Rozdział 3.....	34
Opis eksperymentów i analiza rezultatów	34
Eksperyment 1	35
Sprawdzenie wpływu sposobu stopniowania ograniczenia prędkości na czas przejazdu testowego odcinka drogi	35
Eksperyment 2	39
Sprawdzenie wpływu odległości pomiędzy znakami zmiennej treści na wariancję prędkości pojazdów	39
Eksperyment 3	51
Testowanie modeli rekurencyjnych sieci neuronowych z użyciem danych syntetycznych (inferencja)	51
Rozdział 4	63
Opis realizacji elementów systemu	63
4.1 Kluczowe elementy systemu.....	63
Inteligentny znak drogowy	63
Podsystem łączności	72
Instalacja testowa i model badawczy inteligentnego znaku drogowego.....	75



Rozdział 5	86
Podsumowanie i wnioski.....	86
Bibliografia.....	88
Publikacje autora	98
Dodatki	99
1. Wybrane rysunki konstrukcyjne.....	99
2. Patenty i nagrody	103

Rozdział 1

Wprowadzenie

Zgodnie z danymi opublikowanymi w rocznym raporcie Europejskiego Obserwatorium Bezpieczeństwa Dróg, w 2021 roku na terenie Unii Europejskiej w wypadkach drogowych zginęło 19900 osób, a ponad 0,9 miliona zostało rannych. Aż 71% wypadków miało miejsce na suchej nawierzchni i przy dobrej widoczności [1]. Badania wykazują, że co najmniej 90% (w dokumentach Parlamentu Europejskiego mowa jest o 92%) wypadków drogowych jest spowodowanych przez błąd człowieka [2]–[4]. Eliminacja tych błędów radykalnie poprawiłaby bezpieczeństwo ruchu, a właściwym środkiem do osiągnięcia tego celu jest implementacja zaawansowanych, Inteligentnych Systemów transportowych (ITS). Biorąc pod uwagę średni wiek floty pojazdów (według danych European Automobile Manufacturers' Association (ACEA), na terenie Unii Europejskiej wynosi on 12 lat [5]), konieczne jest uwzględnienie dużej liczby pojazdów, które nie zawierają wyposażenia umożliwiającego współpracę z ITS i zapewnienie koegzystencji z pojazdami skomunikowanymi i zautomatyzowanymi tak, aby bezpieczeństwo na drodze nie było zagrożone [2]. Europejski Komitet Doradczy ds. Badań w dziedzinie Transportu Drogowego (ERTRAC) jest Europejską Platformą Technologiczną (ETP) dla transportu drogowego. ERTRAC jest uznawany i wspierany przez Komisję Europejską. Jako europejska platforma technologiczna, ERTRAC gromadzi ekspertów z branży, ośrodków badawczych i władz publicznych, regularnie aktualizując swój mapę drogową dotyczącą połączonej, współpracującej i zautomatyzowanej mobilności (CCAM), dostarczając wspólny pogląd zainteresowanych stron na długoterminowy rozwój CCAM w Europie. Zgodnie ze wspomnianą mapą drogową, w 2050 r. pojazdy będą w 100% połączone w czasie rzeczywistym z odpowiednią siecią drogową, a system zarządzania transportem będzie miał odpowiedni poziom jakości usług i zdalną obsługę [6].

Pomimo niewątpliwego postępu i sukcesów w dziedzinie CCAM, obecnie prace nadal znajdują się w fazie badań lub testów, trwa więc stan przejściowy, w którym pojazdy skomunikowane stanowią zdecydowaną mniejszość. Ponadto, brak standardów powoduje, że nowe pojazdy, wyposażone już w podsystemy współpracy i komunikacji pomiędzy pojazdami, porozumiewają się między sobą jedynie w ramach producenta. Odległą i zapewne – przynajmniej w świetle bieżących doświadczeń - nieco idealizowaną wizją zaawansowanych ITS byłby rozległy system infrastruktury drogowej, który bezpośrednio, bez udziału człowieka, wymieniałby informacje z w pełni skomunikowanymi i w możliwie dużym stopniu zautomatyzowanymi pojazdami. Docelowo, aby możliwe było całkowite wyeliminowanie błędnych zachowań kierowców, pojazdy te powinny być w pełni autonomiczne. Zrealizowanie takiego planu wiąże się z wieloma trudnościami natury zarówno technicznej i technologicznej, jak i prawnej. Przykładami mogą być wspomniany wyżej problem uzgodnienia standardów

technicznych, problem odpowiedzialności prawnej za skutki wypadków spowodowanych przez pojazdy autonomiczne lub problem prywatności i ochrony danych osobowych [2].

Wobec obecnej skali zjawiska, jakim jest ruch drogowy, słuszne wydaje się założenie, że w celu uniknięcia niepożądanych perturbacji rozwój ITS powinien mieć charakter ewolucyjny, przedmiotem dyskusji natomiast może być tempo planowanych zmian. Tak więc wynikiem konieczności, związanej z bieżącą rzeczywistością, jest koegzystencja kilkunastoletnich pojazdów, tradycyjnych znaków drogowych i nowoczesnych, opartych na najnowszych osiągnięciach technicznych, systemów monitorowania i sterowania ruchem drogowym.

W tym miejscu należy wspomnieć o inicjatywie Parlamentu Europejskiego, dotyczącej wyposażenia starszych pojazdów w moduły Advanced Driver Assistance Systems (ADAS), wspomagające kierowcę i zwiększające bezpieczeństwo ruchu. Wykonane analizy sugerują, że poziom społecznej akceptacji tej inicjatywy jest bardzo mały i bez interwencji ze strony organów Unii Europejskiej liczba zmodernizowanych pojazdów będzie nieznacząca [7].

W świetle powyższych rozważań można stwierdzić, że przy bieżącym stanie techniki optymalnym rozwiązaniem ITS jest hybrydowe połączenie podsystemu obsługującego pojazdy współpracujące i skomunikowane z podsystemem opartym na inteligentnych znakach drogowych. Obydwa wymienione podsystemy mogą być wewnętrznie dowolnie złożone i zaawansowane technologicznie, np. poprzez wykorzystanie sztucznej inteligencji i uczenia maszynowego – co obecnie wydaje się oczywiste – do predykcji sytuacji krytycznych w celu zapobiegania wypadkom. Różnią się jedynie „interfejsem użytkownika”: w pierwszym przypadku będzie to interfejs typu M2M (Machine-to-Machine), wykorzystujący technologię V2X (Vehicle to Everything), w drugim zaś interfejs typu HMI (Human-Machine Interface), w którym elementem zapewniającym interakcję pomiędzy ITS a kierowcą jest inteligentny znak drogowy.

Dla zapewnienia realizacji funkcji związanych z bezpieczeństwem ruchu inteligentne systemy transportowe wykorzystują dane pozyskane zarówno z systemu czujników wbudowanych w infrastrukturę dróg, jak i dane zewnętrzne, np. ze stacji pogodowych. W przypadku wykorzystania autonomicznych inteligentnych znaków drogowych, możliwe jest zbudowanie systemu autonomicznego, realizującego swoje zadania wyłącznie w oparciu o dane dostarczane przez własne, wbudowane czujniki. System taki może pokazywać zalecaną prędkość ruchu, dostosowaną do aktualnych warunków i wyznaczoną za pomocą modeli uczenia maszynowego. Zaimplementowanie mechanizmów uczenia maszynowego umożliwia predykcję warunków zagrażających bezpieczeństwu ruchu i adaptacyjne dostosowanie prędkości pokazywanej na wyświetlaczu znaku.

Inteligentny znak drogowy jest podstawowym elementem adaptacyjnego systemu sterowania ruchem, będącego przedmiotem niniejszej rozprawy. Znak ten wyposażony został w zestaw czujników umożliwiających m.in. monitorowanie ruchu drogowego,

warunków pogodowych, rejestrowanie zdarzeń drogowych w oparciu o analizę danych akustycznych, monitorowanie stanu jezdni. Zawiera również podsystem łączności radiowej, umożliwiającą wymianę informacji pomiędzy sąsiednimi znakami, wchodzącymi w skład systemu. Taki sposób pracy pozwala na obserwowanie i zbieranie informacji z całego obszaru zajmowanego przez instalację, reagowanie na zdarzenia drogowe oraz antycypowanie zagrożeń. Ponadto system zbudowany w oparciu o tak zdefiniowany inteligentny znak drogowy, spełnia wymagania kompatybilności zarówno z pojazdami współpracującymi i skomunikowanymi (dzięki zastosowaniu technologii V2X), jak i pojazdami nie posiadającymi nowoczesnego wyposażenia. Komunikacja, jednostronna w tym przypadku, jest zapewniona poprzez pokazywanie odpowiednich treści na wyświetlaczu znaku, które będą tym samym dostępne dla kierujących pojazdami [8].

1.1 Geneza i cel pracy

Podjęte prace były istotnym składnikiem przedsięwzięcia, polegającego na opracowaniu algorytmów wyznaczania przez adaptacyjny system sterowania zalecanej prędkości ruchu pojazdów na podstawie danych pozyskiwanych przez zestaw czujników wchodzących w skład opracowanych inteligentnych znaków drogowych.

Inspiracją do podjęcia tematu adaptacyjnego systemu sterowania ruchem drogowym był realizowany w okresie od 2017-2020 r. i zaakceptowany oraz rozliczony w maju 2021 r. projekt badawczo-rozwojowy pt.: „INZNAK - Inteligentne znaki drogowe do adaptacyjnego sterowania ruchem pojazdów, komunikujące się w technologii V2X”. Projekt ten zrealizowany został na Wydziale Elektroniki, Telekomunikacji i Informatyki Politechnice Gdańskiej, we współpracy z Akademią Górniczo-Hutniczą w Krakowie i dwiema firmami z województwa pomorskiego (Siled sp. z o. o. i Microsystems sp. z o. o.) i był dofinansowany przez NCBR w ramach programu „Projekty aplikacyjne” POIR 4.1.4 (nr POIR.04.01.04-00-0089/16) [8]. Opracowane w ramach projektu rozwiązania otworzyły nowe możliwości z zakresie rozwoju prac koncepcyjnych i badawczych związanych z adaptacyjnym sterowaniem ruchem drogowym. Prace zrealizowane w tym przedmiocie przez autora są osnową niniejszej rozprawy.

Opracowywane w ramach projektu inteligentne znaki drogowe komunikują prędkość obliczoną na podstawie mierzonych przez nie ruchu pojazdów oraz na podstawie informacji otrzymanych z ciągu podobnych znaków zmiennej treści, rozmieszczonych wzdłuż odcinka drogi, połączonych ze sobą za pośrednictwem sieci bezprzewodowej. Ich szczególną cechą jest możliwość działania autonomicznego, ponieważ komunikowana przez znaki zalecana prędkość jest wynikiem dokonywanych przez nie bezpośrednich pomiarów ruchu drogowego. Wyświetlana przez znaki treść, czyli zalecana prędkość jazdy, jest komunikowana również bezprzewodowo za pomocą technologii V2X do pojazdów wyposażonych w odpowiedni interfejs.

Aktywne znaki drogowe skonstruowane zostały w wersji wolnostojącej,

przeznaczonej do montażu na słupach na poboczu jezdni oraz w wersji przeznaczonej do zawieszenia na bramownicach. W czasie trwania projektu zrealizowano badania terenowe, które umożliwiły udoskonalenie czujników zainstalowanych w znakach oraz zaimplementowanych algorytmów.

Konsekwencją unikalnych cech opisywanych inteligentnych znaków drogowych była idea zbudowania za ich pomocą adaptacyjnego systemu sterowania ruchem drogowym. System taki, składający się z wielu autonomicznych i skomunikowanych bezprzewodowo znaków, spełniałby swoje zadania w oparciu o wielomodalną (akustyczną, wizyjną i mikrofalową) analizę ruchu drogowego oraz wielomodalne monitorowanie warunków ruchu. Tak duże możliwości zapewnione zostały dzięki opracowanym podczas trwania projektu udoskoleniom radaru dopplerowskiego oraz dzięki opracowaniu oryginalnego, wektorowego czujnika akustycznego. Czujnik ten, będący przedmiotem patentu [9], umożliwia zarówno pomiar prędkości pojazdów, jak i śledzenie ich ruchu oraz ułatwia ich klasyfikowanie rodzajowe. Ponadto, możliwe jest także monitorowanie za jego pomocą stanu nawierzchni drogi. Funkcja określania stanu nawierzchni drogi zaimplementowana została również za pomocą modalności wizyjnej, poprzez zastosowanie inteligentnych metod przetwarzania obrazu oraz technik uczenia maszynowego. Opracowana sztuczna sieć neuronowa zapewniła podczas przeprowadzonych badań skuteczność automatycznej klasyfikacji na poziomie ponad 97% [10].

Opisane wyżej inteligentne znaki drogowe są głównym elementem adaptacyjnego systemu sterowania ruchem drogowym. Opracowanie skutecznego i efektywnego algorytmu, a właściwie algorytmów, działania wymaga zbadania wielu aspektów ruchu drogowego, jak i samej konstrukcji fizycznej systemu sterowania, które mają, lub mogą mieć wpływ na bezpieczeństwo i płynność ruchu pojazdów.

Uwaga autora niniejszej pracy została skoncentrowana na trzech zagadnieniach: pierwszym z nich jest wpływ metody stopniowania ograniczenia prędkości pojazdów na płynność ruchu i czas przejazdu odcinka drogi objętego ograniczeniem prędkości. W celu zbadania tego wpływu przeprowadzona została seria eksperymentów symulacyjnych, obejmujących kilka typów dróg krajowych.

Drugim aspektem analizowanym w pracy jest wpływ fizycznej topologii systemu (w tym przypadku, odległości pomiędzy znakami wprowadzającymi ograniczenie prędkości) na wariację prędkości pojazdów w wybranych, krytycznych punktach drogi. Badania wykazują, że wzrost wariacji prędkości powoduje istotny wzrost wskaźnika wypadkowości [11] i ryzyka wypadków [12], [13]. W literaturze można spotkać stwierdzenie, że oddzielenie wpływu średniej prędkości i wariacji prędkości na wypadki jest trudne, jednak faktem jest, że wzrost wariacji prędkości powoduje wzrost ilości sytuacji konfliktowych na drodze, co prowadzi do zwiększenia ryzyka kolizji [14]. Tak jak poprzednio, badania przeprowadzone zostały w drodze eksperymentów symulacyjnych. Model symulacyjny zbudowany został na bazie odcinka Drogi Kaszubskiej, pomiędzy skrzyżowaniem z ulicą Gdynską i miejscowością Wieżyca.

Trzecim i ostatnim analizowanym aspektem była możliwość testowania modelu głębokiej rekurencyjnej sieci neuronowej, wytrenowanego na danych rzeczywistych, za pomocą danych syntetycznych, uzyskanych w drodze symulacji. Model ten, będący istotną częścią adaptacyjnego systemu sterowania ruchem drogowym, służy do predykcji parametrów ruchu. Ponieważ dane rzeczywiste pochodzące z konkretnej lokalizacji nie zawsze są dostępne, sprawdzenie skuteczności inferencji na danych syntetycznych jest istotne z punktu widzenia fizycznej implementacji modeli uczenia maszynowego w systemie sterowania.

Opisane w rozdziale drugim eksperymenty były podstawą do weryfikacji postawionych w niniejszej pracy tez:

1. Za pomocą odpowiedniego doboru stopniowania prędkości możliwe jest zmniejszenie czasu przejazdu odcinka drogi, na którym ustawiono znaki zmiennej treści wyświetlające ograniczenia prędkości.
2. Za pomocą doboru odległości pomiędzy znakami ograniczenia prędkości oraz stopnia redukcji prędkości zalecanej możliwe jest zmniejszenie wariacji prędkości pojazdów.
3. W celu walidacji modeli sterowania ruchem wytrenowanych za pomocą danych rzeczywistych, wystarczające jest ich testowanie za użyciem danych syntetycznych.

1.2 Zawartość rozprawy

Niniejsza rozprawa składa się z pięciu rozdziałów tematycznych, bibliografii oraz rozdziału zawierającego dodatki.

Rozdział pierwszy zawiera:

- wprowadzenie odnoszące się do głównych przyczyn zagrożeń w ruchu drogowym oraz krótki opis strategii zapobiegania tym zagrożeniom wdrażany przez Unię Europejską
- opis genezy i celu pracy
- opis zawartości rozprawy

Rozdział drugi zawiera:

- przegląd matematycznych modeli zachowań kierowców
- przegląd technik uczenia maszynowego stosowanych do analizy i predykcji ruchu drogowego

Rozdział trzeci zawiera opis trzech eksperymentów symulacyjnych oraz analizę rezultatów.

Rozdział czwarty zawiera opis realizacji wybranych elementów autonomicznego systemu sterowania ruchem drogowym, rozdział piąty – podsumowanie i wnioski.

W dodatkach pracy przedstawiono wybrane rysunki konstrukcyjne inteligentnego znaku drogowego, pełną listę publikacji autora oraz otrzymane nagrody i patenty.

Rozdział 2

Modelowanie ruchu drogowego

Wymienione w rozdziale 1 problemy badawcze dotyczą analizy i predykcji parametrów ruchu drogowego, a przyjęta metoda badawcza opierała się na symulacjach, stąd w pierwszej części niniejszego rozdziału zostanie przedstawiony przegląd matematycznych modeli zachowań kierowców (2.1). Przegląd ten stanowi wstęp do dwóch eksperymentów, przeprowadzonych z użyciem symulatora Vissim [15]. Celem eksperymentów było zweryfikowanie pierwszych dwóch tez sformułowanych w rozdziale 1. Symulator Vissim wykorzystuje dwa z opisanych w podrozdziale 2.1 modeli zachowania kierowców. Zawarty w podrozdziale 2.2 przegląd technik uczenia maszynowego stosowanych w Inteligentnych Systemach Transportowych, stanowi wstęp do trzeciego eksperymentu, w którym wykorzystano głębokie rekurencyjne sieci neuronowe. Eksperyment ten miał na celu zweryfikowanie poprawności trzeciej tezy sformułowanej w rozprawie. Eksperymenty oraz otrzymane rezultaty zostały szczegółowo opisane w rozdziale trzecim.

2.1 Matematyczne modele zachowań kierowców

Początek prac nad sformułowaniem modeli opisujących zachowanie pojazdów sięga lat pięćdziesiątych dwudziestego wieku [16]. Literatura przedmiotu zawiera obecnie dziesiątki modeli o różnych właściwościach, przeznaczonych do zastosowania w różnych obszarach badania ruchu drogowego. Do najpopularniejszych można zaliczyć:

- Model Nagel-Schreckenberga (NaSch): Jest to jeden z najprostszych modeli opisujących ruch drogowy. Model ten zakłada, że kierowcy poruszają się pojedynczo na jednowymiarowej drodze i podejmują decyzje na podstawie ograniczeń prędkości, odległości od poprzedzającego pojazdu oraz reakcji na zmiany w ruchu.
- Model Intelligent Driver Model (IDM): IDM to model, który stara się opisać zachowanie kierowców w warunkach zatłoczonego ruchu. Opiera się na założeniu, że kierowcy dostosowują swoją prędkość do prędkości pojazdu przed nimi, aby utrzymać bezpieczną odległość.
- Model Optimal Velocity (OV): OV jest modelem, który analizuje zachowanie kierowców na podstawie ich prędkości optymalnej. Kierowcy starają się utrzymać prędkość, która minimalizuje ich czas podróży, biorąc pod uwagę ograniczenia ruchowe.
- Model Psychologiczny (Psychological Model): Ten model bada psychologiczne aspekty zachowania kierowców. Zakłada, że kierowcy podejmują decyzje na

drodze na podstawie swojego poziomu uwagi, stresu, zmęczenia i innych czynników psychologicznych.

- Model Kaskadowy (Cascade Model): Model ten opisuje zachowanie kierowców na podstawie reakcji na sytuację na drodze. Zakłada, że kierowcy dzielą się na grupy, z których każda reaguje na zmiany w ruchu w oparciu o reakcje poprzedzającej grupy.

Należy zauważyć, że modele są uproszczonymi reprezentacjami zachowania kierowców i nie uwzględniają wszystkich czynników wpływających na ruch drogowy. Rzeczywiste zachowanie kierowców jest znacznie bardziej złożone i zależy od wielu czynników, takich jak doświadczenie, umiejętności, sytuacja drogowa, warunki atmosferyczne np.

Modele te można sklasyfikować na różne sposoby, uwzględniając różne aspekty i zachowania, np.:

1. Klasyfikacja na podstawie zachowań kierowców:

- Modele jazdy za liderem (car-following model): Koncentrują się na symulowaniu zachowania kierowców podążających za liderem pojazdu. Jest to jeden z najważniejszych i najczęściej używanych rodzajów modeli mikroskopowych. Modele jazdy za liderem są zwykle podzielone na klasy w zależności od wykorzystywanej logiki. Do klas tych należą:
 - Modele Gazisa-Hermana-Rothery'ego (GHR) [17], [18]. Modele te zakładają, że przyspieszenie pojazdu podążającego a_n jest proporcjonalne do jego prędkości v_n , różnicy prędkości między pojazdem podążającym a prowadzącym Δv oraz odwrotnie proporcjonalne do odstępu pomiędzy pojazdami Δx . Przyspieszenie to opisywane jest następującym równaniem [18]:

$$a_n(t) = cv_n^m(t) \frac{\Delta v(t-T)}{\Delta x^l(t-T)} \quad (1)$$


Gdzie $c > 0$, m i l są współczynnikami proporcjonalności modelu, które wymagają ustalenia, T jest czasem reakcji kierowcy.

- Modele bezpiecznej odległości. Modele bezpiecznej odległości opierają się na założeniu, że kierowca zawsze utrzymuje bezpieczną odległość Δx od pojazdu poprzedzającego. Odległość ta jest proporcjonalna do prędkości pojazdu poprzedzającego v_{n-1} i prędkości pojazdu podążającego v_n . Równanie opisujące model bezpiecznej odległości zostało sformułowane po raz pierwszy w 1959 roku i wyglądało następująco [18]:

$$\Delta x(t-T) = \alpha v_{n-1}^2(t-T) + \beta_l v_n^2(t) + \beta v_n(t) + b_0 \quad (2)$$

Wartość wszystkich współczynników równania została wyznaczona eksperymentalnie. W 1981 roku Gipps przedstawił ulepszenie oryginalnego modelu [19]. W modelu Gippsa podążający ma gwarancję, że nie zderzy się z liderem, jeśli odstęp czasowy od lidera jest większy lub równy $3T/2$, a oszacowane przez podążającego opóźnienie lidera jest większe lub równe jego opóźnieniu rzeczywistemu [18]. Bliższe omówienie tego modelu znajduje się w dalszej części niniejszego paragrafu.

- o Psychofizyczne modele podążania za liderem, zwane również modelami punktów działania (Action Point models) [18]. Modele te wykorzystują progi dla, np. minimalnej różnicy prędkości między pojazdem podążającym a prowadzącym, postrzeganej przez kierowcę pojazdu podążającego. Pierwotna koncepcja zakładała, że kierowcy początkowo byłoby w stanie stwierdzić, że zbliżają się do pojazdu poprzedzającego, głównie z powodu zmian w pozornym rozmiarze pojazdu, postrzegając względną prędkość poprzez zmiany kąta widzenia obejmującego pojazd poprzedzający. Diagram ilustrujący działanie psychofizycznego modelu podążania za liderem przedstawiony jest na rys. 1. Reprezentatywnym przedstawicielem tej grupy jest model Wiedemanna 99, bliżej omówiony w dalszej części niniejszego paragrafu.



Rys. 1. Psychofizyczny model typu car-following.

- Modele zmiany pasa ruchu: Skupiają się na symulacji zachowań związanych ze zmianą pasa ruchu, takich jak sygnalizacja, poszukiwanie luki np.
- Modele hamowania awaryjnego: Symulują sytuacje nagłego hamowania i reakcje kierowców na niebezpieczne warunki drogowe lub zdarzenia na drodze.

- Modele wyprzedzania: Uwzględniają zachowania związane z wyprzedzaniem innych pojazdów na drodze.
- Modele skręcania: Koncentrują się na symulacji zachowań kierowców podczas skręcania na skrzyżowaniach i zmieniania kierunku jazdy.

2. Klasyfikacja na podstawie rodzaju symulowanej drogi:

- Modele autostradowe: Skupiają się na symulacji ruchu na autostradach i drogach o wysokiej przepustowości.
- Modele miejskie: Dotyczą symulacji ruchu w obszarach miejskich, uwzględniając skrzyżowania, sygnalizację świetlną i inne elementy charakterystyczne dla miasta.
- Modele drogowe o różnym podłożu: Symulują różne rodzaje dróg, takie jak drogi dwupasmowe, drogi jednopasmowe, drogi wiejskie np., uwzględniając ich specyficzne cechy i ograniczenia.

3. Klasyfikacja na podstawie rodzaju modelu matematycznego:

- Modele oparte na automatach komórkowych: Wykorzystują reguły opisujące zachowania poszczególnych pojazdów i ich interakcje.
- Modele oparte na równaniach hydrodynamicznych: Używają równań opisujących przepływ pojazdów na drodze w sposób podobny do przepływu cieczy.
- Modele oparte na teorii sterowania: Wykorzystują zasady teorii sterowania do modelowania zachowań kierowców i regulacji ruchu drogowego.
- Modele oparte na uczeniu maszynowym: Korzystają z algorytmów uczenia maszynowego do analizy danych i predykcji zachowań kierowców na podstawie zebranych danych.

Klasyfikacja modeli symulacji ruchu drogowego może być bardziej szczegółowa i zależeć od konkretnego kontekstu badawczego. Może na nią wpływać wiele innych czynników, takich jak uwzględnienie transportu publicznego, pieszych, rowerzystów np.

Biorąc pod uwagę skalę analizy, można wyróżnić trzy główne kategorie: modele mikroskopowe, mezoskopowe i makroskopowe. Kategorie te różnią się poziomem szczegółowości oraz zakresem analizy i można je scharakteryzować następująco:

1. Modele mikroskopowe:

Modele mikroskopowe zajmują się analizą ruchu drogowego na bardzo szczegółowym poziomie, biorąc pod uwagę indywidualne pojazdy i ich kierowców. Wymagają dokładnych danych o każdym pojeździe na drodze, takich jak położenie, prędkość, przyspieszenie, preferencje kierowcy np.

Zastosowanie: Modele mikroskopowe są przydatne do analizy szczegółowych sytuacji drogowych, takich jak skrzyżowania, zmiany pasa ruchu, wyprzedzanie, reakcje na sytuacje awaryjne np.

2. Modele mezoskopowe:

Modele mezoskopowe koncentrują się na analizie grupy pojazdów lub obszaru drogi, a nie na indywidualnych pojazdach. Wymagają danych dotyczących grupy pojazdów, takich jak średnia prędkość, gęstość ruchu, struktura ruchu np.

Zastosowanie: Modele mezoskopowe są użyteczne do analizy wydajności dróg, przepustowości, efektywności sygnalizacji świetlnej, obszarów o dużym ruchu np.

3. Modele makroskopowe:

Modele makroskopowe analizują ruch drogowy na poziomie agregatów, takich jak gęstość ruchu i przepływ pojazdów, a nie indywidualnych pojazdów. Analizują ruch na poziomie całej sieci drogowej lub dużych obszarów i wymagają danych makroskopowych, takich jak całkowita liczba pojazdów, przepustowość drogi, średnia prędkość np.

Zastosowanie: Modele makroskopowe są użyteczne do analizy globalnej wydajności sieci drogowej, prognozowania zatłoczenia, oceny obciążenia sieci np.

W praktyce, modele mikroskopowe, mezoskopowe i makroskopowe są często stosowane jednocześnie, aby uzyskać kompleksowy obraz ruchu drogowego w różnych skalach i sytuacjach.

Obecnie, do najpopularniejszych modeli mikroskopowych zachowania kierowcy należą:

1. Model Nagel-Schreckenberga [20]–[22] (model automatów komórkowych):

w modelu tym droga jest reprezentowana za pomocą jednowymiarowej tablicy składającej się z L komórek. Każda komórka może być pusta lub zajęta przez pojazd. Prędkość pojazdu jest liczbą całkowitą, zawartą w przedziale $\langle 0, v_{max} \rangle$ i równą liczbie komórek, które pojazd przeskakuje w każdym kroku czasowym. Każda aktualizacja modelu składa się z czterech, następujących po sobie kroków, które są wykonywane równoległe dla każdego pojazdu:

- 1) **Przyspieszenie:** jeżeli prędkość $v < v_{max}$ i jeżeli odległość do poprzedzającego pojazdu jest większa niż $v+1$, prędkość pojazdu jest zwiększana o 1 ($v = v+1$).
- 2) **Hamowanie:** jeżeli pojazd w komórce i widzi poprzedzający pojazd w komórce $i + j$ (przy $j \leq v$), wówczas redukuje prędkość do wartości $j - 1$ ($v = j - 1$).
- 3) **Randomizacja:** z prawdopodobieństwem p prędkość każdego pojazdu



(jeżeli jest większa od zera) jest zmniejszana o 1 ($v = v - 1$).

4) **Ruch pojazdu:** każdy pojazd jest przesuwany o v komórek.

Model Nagela-Schreckenberga jest modelem stochastycznym. Który uwzględnia niedoskonałości jazdy za pomocą szumu w regułach aktualizacji i dość dobrze odtwarza empiryczną zależność prędkość-gęstość i spontaniczne grupowanie [16]. Jest też oszczędny obliczeniowo [21].

2. **Model Inteligentnego Kierowcy (IDM – Intelligent Driver Model):** został zaproponowany przez Martina Treibera w 2000 roku [23]. Jest to model typu car-following, przeznaczony do mieszanych warunków ruchu i opisujący przyspieszenie $\frac{d}{dt}v_\alpha(t)$ jako funkcję odstępów pomiędzy pojazdami s_α , prędkości pojazdu podążającego v_α i różnicy prędkości między pojazdem podążającym a pojazdem poprzedzającym Δv_α za pomocą następującego równania [23]:

$$\frac{d}{dt}v_\alpha(t) = a^{(\alpha)} \left[1 - \left(\frac{v_\alpha}{v_0^{(\alpha)}} \right)^\delta - \left(\frac{s^*(v_\alpha, \Delta v_\alpha)}{s_\alpha} \right)^2 \right] \quad (3)$$

gdzie:

v_α jest prędkością pojazdu „ α ” (podążającego)

a jest maksymalnym przyspieszeniem

v_0 jest prędkością jazdy swobodnej (prędkością pożądaną)

s^* jest pożądanym minimalnym odstępem

s_α jest odstępem rzeczywistym

Pożyczany minimalny odstęp s^* opisany jest jako:

$$s^*(v, \Delta v) = s_0^{(\alpha)} + s_1^{(\alpha)} \sqrt{\frac{v}{v_0^{(\alpha)}}} + T^\alpha v + \frac{v \Delta v}{2\sqrt{a^{(\alpha)} b^{(\alpha)}}} \quad (4)$$

gdzie:

s_0 jest bezpiecznym odstępem pomiędzy stojącymi pojazdami (bezpieczna odległość zatoru); typowa wartość 2 m

s_1 jest minimalnym odstępem pomiędzy stojącymi pojazdami (minimalna odległość zatoru); typowa wartość 0 m

T jest bezpieczną odległością czasową, (odległość czasowa jest tu rozumiana jako odstęp czasowy między momentem, gdy jeden pojazd opuszcza pewien punkt pomiarowy a momentem, gdy kolejny pojazd przekracza ten sam punkt pomiarowy).

b jest pożądanym opóźnieniem

Pożądaný minimalny odstęp s^* zmienia się dynamicznie wraz z prędkością własną pojazdu „ α ” (podążającego) i prędkością zbliżenia do pojazdu poprzedzającego.

Algorytmy IDM zostały przyjęte jako podstawa konstrukcji modelu przy formułowaniu potencjalnego zachowania pojazdów autonomicznych, zaawansowanych funkcji wspomagania kierowcy, takie jak adaptacyjny tempomat (ACC) i współpracujący adaptacyjny tempomat [24].

3. Model Optymalnej Prędkości (OVM) [24], [25]: Model optymalnej prędkości (OVM) przedstawia dynamiczny opis korków drogowych za pomocą równania ruchu dla każdego pojazdu. W tym modelu przepływu ruchu drogowego bodziec jest funkcją odstępów pomiędzy pojazdami i wszyscy kierowcy posiadają stałą wrażliwości na bodźce. W modelu przyjęto trzy założenia [25]:

- Każdy kierowca reaguje na bodziec z poprzedzającego pojazdu i porusza się z prędkością V , zgodną z przepisami ruchu drogowego.
- Każdy kierowca kontroluje przyspieszanie/zwalnianie obserwując ruch poprzedzającego pojazdu w celu utrzymania bezpiecznej prędkości
- Nie jest brany pod uwagę czas opóźnienia reakcji.

Przy powyższych założeniach przyspieszenie n -tego pojazdu opisane zostało równaniem (x):

$$\ddot{x}_n(t) = a\{V(\Delta x_n) - \dot{x}_n(t)\} \quad (5)$$

gdzie

$$\Delta x_n = x_{n+1} - x_n \text{ dla każdego pojazdu } n \text{ (} n = 1, 2, \dots, N \text{)}$$

N jest całkowitą liczbą pojazdów

a jest stałą reprezentującą wrażliwość kierowcy (niezależną od n)

x_n jest współrzędną n -tego pojazdu

Prędkość $V(x)$ n -tego pojazdu jest zależna od odstępów od pojazdu poprzedzającego, tzn. pojazdu $n+1$. Jeśli odstęp maleje, prędkość musi być zredukowana do wartości uniemożliwiającej kolizję. Jeśli odstęp powiększa się, wówczas prędkość może być zwiększona, nie przekraczając jednak dopuszczalnej wartości maksymalnej [25].

Badania stabilności modelu doprowadziły do sformułowania optymalnej prędkości za pomocą równania (x):

$$V(\Delta x_n) = \tanh(\Delta x - 2) + \tanh(2) \quad (6)$$

Zgodnie z powyższym równaniem, kierowca zarządza przyspieszaniem i hamowaniem i nigdy nie powodując kolizji, przepływ ruchu natomiast tworzy zjawiska zatorów zamiast wypadków.

Słabością modelu OVM jest rozwijanie idealistycznie dużych przyspieszeń w niektórych warunkach [24].

4. **Model Kraussa** [16]: opisuje zachowanie kierowców na podstawie ich reakcji na odległość do pojazdu przed nimi, prędkość pojazdu przed nimi i przyspieszenie. Model ten uwzględnia różne style jazdy kierowców i asymetrię reakcji na przyspieszanie i hamowanie.

Model Kraussa (znany również jako Model decyzji Kraussa) to jeden z popularnych modeli matematycznych, który opisuje zachowanie kierowców w kontekście zmiany pasa ruchu. Model ten został opracowany przez J.D. Kraussa w 1991 roku i od tego czasu był szeroko stosowany w badaniach dotyczących ruchu drogowego.

Model Kraussa opisuje proces podejmowania decyzji przez kierowców dotyczący zmiany pasa ruchu na podstawie obserwacji innych pojazdów i oceny luki w ruchu. W modelu założono, że kierujący pojazdem podejmuje decyzję o zmianie pasa ruchu tylko wówczas, gdy jest spełnione są pewne kryteria. Kryteria te obejmują np. dystans od innych pojazdów, różnicę prędkości między pasami, dostępność wolnej przestrzeni na docelowym pasie oraz ocenę ryzyka związanego z manewrem zmiany pasa.

W modelu Kraussa wyróżnia się trzy główne procesy:

1. Proces percepcji: kierowca obserwuje ruch na drodze i odbiera informacje dotyczące innych pojazdów, takie jak ich pozycja, prędkość i odległość.
2. Proces oceny: na podstawie zgromadzonych informacji kierowca ocenia, czy luka w ruchu jest odpowiednia do wykonania manewru zmiany pasa. W ocenie uwzględniane są różne czynniki, takie jak prędkość innych pojazdów, różnica prędkości między pasami i dostępność wolnej przestrzeni na docelowym pasie.
3. Proces decyzyjny: na podstawie oceny luki w ruchu kierowca podejmuje decyzję o zmianie pasa lub pozostaniu na bieżącym pasie.

Model Kraussa może być uważany za podejście alternatywne do modelu Gippsa, ponieważ pozwala na przezwycięzenie dwóch głównych jego ograniczeń: jego nieprzydatności w przypadku niestabilnych warunków przepływu ruchu i możliwości, że model nie ma rozwiązań ze względu na jego analityczne sformułowanie [26].

Podstawowe założenia modelu są następujące:

- Podczas jazdy swobodnej pojazdy poruszają się z prędkością nie przekraczającą pewnej wartości maksymalnej v_{max} , interpretowanej jako prędkości pożądanej: $v \leq v_{max}$.

- Kierowca zawsze wybiera prędkość nie przekraczającą prędkości bezpiecznej v_{safe} : $v \leq v_{safe}$

Bezpieczna prędkość w modelu Kraussa opisana jest następującym równaniem:

$$v_{safe} = v_l + \frac{g(t) - v_l(t)t_r}{\frac{v_l(t) + v_f(t)}{2b} + t_r} \quad (7)$$

Pożądana prędkość natomiast jest równa minimum pomiędzy prędkością maksymalną, prędkością do której pojazd może przyspieszyć oraz powyżej zdefiniowaną prędkością bezpieczną:

$$v_{des} = \min[v_{max}, v + at, v_{safe}] \quad (8)$$

Model Kraussa jest często wykorzystywany w symulacjach ruchu drogowego i badaniach nad zmianą pasa ruchu. Umożliwia on analizę wpływu różnych czynników, takich jak natężenie ruchu, prędkość, czasy reakcji kierowców np., na zachowanie się kierowców w kontekście zmiany pasa ruchu.

5. **Model Gippsa** [19] (nazywany modelem zachowania bezpiecznej odległości): opisuje zachowanie kierowców na drodze na podstawie ich intencji dotyczących zmiany pasa ruchu i reakcji na pojazdy przed nimi. Model ten jest przedstawiany za pomocą następującego równania:

$$v_n(t + \tau) = \min \left\{ \begin{array}{l} v_n(t) + 2.5a_n\tau \left(1 - \frac{v_n}{V_n}\right) \sqrt{0.025 + \frac{v_n}{V_n}}, \\ b_n\tau + \sqrt{(b_n^2\tau^2 - b_n[2[x_{n-1}(t) - s_{n-1} - x_n(t)]] - v_n(t)\tau - \frac{v_{n-1}(t)^2}{\hat{b}})} \end{array} \right. \quad (9)$$

gdzie:

- a_n jest przyspieszeniem pojazdu n , w [19] przyjęto jako próbka z rozkładu normalnego $N(1.7, 0.3^2)$ m/s²
- b_n jest maksymalnym opóźnieniem (hamowaniem, $b_n < 0$), w [19] przyjęto wartość $-2.0a_n$
- s_n jest efektywną długością pojazdu n (fizyczna długość plus margines odległości do pojazdu następnego),
- V_n jest pożądaną prędkością pojazdu n
- $x_n(t)$ jest położeniem frontu pojazdu n w czasie t
- v_n jest prędkością pojazdu n w czasie t
- τ jest czasem reakcji, stałym dla wszystkich pojazdów, w [19] przyjęto wartość 2/3 s
- \hat{b} jest równe $\min\{-3.0, (b_n - 3.0)/2\}$ m/s²

Model Gippsa opisuje zachowanie kierowców na podstawie ich prędkości,

przyspieszenia oraz odległości od innych pojazdów. Model zakłada, że kierowcy dążą do utrzymania bezpiecznej odległości od poprzedzającego pojazdu oraz do osiągnięcia żądanej prędkości. Model uwzględnia również fakt, że kierowcy reagują na zmiany w otoczeniu, takie jak zmiany prędkości innych pojazdów, ograniczenia drogowe np.

Podstawowe założenia modelu Gippsa obejmują:

- Przyrost prędkości: Kierowcy dążą do osiągnięcia żądanej prędkości i przyspieszają, jeśli są w stanie to zrobić bezpiecznie.
- Bezpieczna odległość: Kierowcy starają się utrzymać bezpieczną odległość od poprzedzającego pojazdu, co oznacza, że dostosowują swoją prędkość, aby uniknąć kolizji.
- Reakcja na zmiany: Kierowcy reagują na zmiany prędkości i przyspieszenia innych pojazdów w swoim otoczeniu.

Model Gippsa jest szeroko stosowany w analizach i symulacjach ruchu drogowego.

6. Modele Wiedemanna

Psychofizyczny model podążania za liderem, znany pod nazwą Wiedemann 74 (W-74), został po raz pierwszy opracowany przez Rainera Wiedemanna w 1974 roku [27], a następnie udoskonalony w 1992 r. przez Wiedemanna i Reitera [28], który obecnie nosi nazwę Wiedemann 99 (W-99) car-following model. Obydwa modele wykorzystywane są w programie symulacyjnym Vissim.

Podstawowe założenia modeli Wiedemanna są następujące:

- Zagęszczenie pojazdów: Im większe zagęszczenie pojazdów, tym niższa prędkość ruchu.
- Prędkość: Prędkość ruchu jest zależna od zagęszczenia pojazdów i innych czynników, takich jak ograniczenia prędkości i natężenie ruchu.
- Przepustowość drogi: Przepustowość drogi jest maksymalnym zagęszczeniem pojazdów, które może obsłużyć przy danej prędkości.


Modele te różnią się niektórymi założeniami i rozszerzeniami, a główne różnice między nimi obejmują:

- Rozszerzenia modelu: Model Wiedemanna 99 wprowadza kilka rozszerzeń w porównaniu do modelu Wiedemanna 74. Model 99 uwzględnia na przykład wpływ zmienności prędkości pojazdów, bardziej precyzyjne uwzględnienie zmiany prędkości w trakcie przyspieszania i hamowania, a także uwzględnia aspekty psychologiczne i behawioralne kierowców.

- Charakterystyki kierowców: Model Wiedemanna 99 uwzględnia różne typy kierowców i ich zachowania na drodze. Modele te uwzględniają indywidualne preferencje kierowców, takie jak różnice w stylu jazdy, poziomie agresywności i tendencji do utrzymania większych odstępów od innych pojazdów.
- Uwzględnienie różnych typów dróg: Model Wiedemanna 99 uwzględnia różne rodzaje dróg, takie jak autostrady, drogi dwujezdniowe i drogi jednojezdniowe. Model ten bierze pod uwagę charakterystyki tych dróg i uwzględnia różnice w przepustowości i prędkości dla różnych rodzajów dróg.
- Poprawki empiryczne: Model Wiedemanna 99 zawiera poprawki empiryczne, które zostały opracowane na podstawie danych z badań terenowych i obserwacji ruchu drogowego. Te poprawki mają na celu lepsze odzwierciedlenie rzeczywistych zachowań kierowców i warunków drogowych.

W obu modelach Wiedemanna instrumentami służącymi do zmiany zachowania kierowcy są progi percepcji, po przekroczeniu których kierowca reaguje na bieżącą sytuację zmieniając parametry jazdy. W modelach zdefiniowane zostały cztery tryby jazdy [29], przedstawione na rys. 2:

- **Tryb jazdy swobodnej:** pojazd znajduje się poza wpływem innych uczestników ruchu i jedzie z zamierzoną prędkością
- **Tryb dojeżdżania (zbliżania się do pojazdu poprzedzającego):** kierowca zauważył wolniej jadący pojazd poprzedzający i zwalnia, dostosowując swoją prędkość do prędkości lidera i odstęp do wielkości zamierzonej, wchodząc tym samym w tryb podążania za liderem.
- **Tryb podążania za liderem:** kierowca podąża za liderem, próbując utrzymując stały odstęp i zerową prędkość względną przy użyciu stosunkowo niskich przyspieszeń lub opóźnień. Wskutek niedoskonałości szacowania prędkości powoduje, że, prędkość własna może być mniejsza niż prędkość lidera. Kierowca może więc ponownie nieznacznie przyspieszyć po osiągnięciu kolejnego progu percepcji, powodując nieznaczne oscylacje prędkości i dystansu (powstaje efekt histerezy). Efekt ten widoczny jest na rys. 2.
- **Tryb hamowania awaryjnego:** jeśli odstęp do lidera zmniejszy się poniżej wartości krytycznej, kierowca pojazdu podążającego reaguje maksymalnym możliwym hamowaniem aby uniknąć kolizji.



Rys. 2. Progi percepcji modelu Wiedemanna

Oznaczenia na rys. 2:

AX: Odległość postojowa: pożądana minimalna odległość między dwoma stojącymi pojazdami (prowadzącym i podążającym). Wartość dla tego parametru jest stała.

BX: Minimalna odległość podążania za pojazdem prowadzącym (liderem).

CLDV: Próg percepcji bliski: w odległości mniejszej niż SDX kierowca zauważa, że jego własna prędkość jest większa niż prędkość lidera.

SDV: Próg percepcji daleki: w odległości większej niż SDX kierowca zauważa, że zbliża się do wolniej jadącego pojazdu.

OPDV: Próg percepcji bliski: w odległości mniejszej niż SDX kierowca zauważa, że jego własna prędkość jest mniejsza niż prędkość lidera.

SDX: Próg percepcji: maksymalna odległość podążania będąca górną granicą trybu podążania. Powyżej tej granicy pojazd przechodzi w tryb jazdy swobodnej.

W stanie ustalonym trybu podążania za liderem, tzn. gdy $s_n \approx s_{desidered}$ i $\Delta v_n \approx 0$, gdzie s_n jest odstępem pomiędzy pojazdem prowadzącym (liderem) a podążającym, Δv_n jest różnicą prędkości lidera i pojazdu podążającego ($V_{n-1} - v_n$), s_j jest odstępem pomiędzy stojącymi (w korku) pojazdami, prędkość pojazdu podążającego w modelu W-74 opisana jest następującym równaniem [30]:

$$v_n(t + \Delta t) = \min \left\{ 3.6 \left(\frac{s_n(t) - s_j}{BX} \right)^2, v_f, 3.6 \left(\frac{s_n(t) - s_j}{BX \times EX} \right)^2 \right\} \quad (10)$$

Pożądany odstęp pomiędzy pojazdami (liderem i podążającym) znajduje się w przedziale ($ABX \leq s \leq SDX$). Przy założeniu, że $\Delta v_n \approx 0$ oczekiwane wartości ABX i SDX wyznaczone są z zależności [15], [30]:

$$E(AX) = s_j + AX_{add} + AX_{mult}E(RND1_n) = s_j + 0,5 \approx s_j \quad (11)$$

$$E(ABX) = E(AX) + E(BX)\sqrt{v} = s_j + E(BX)\sqrt{v}, \quad v \leq v_{desired} \quad (12)$$

$$E(SDX) = s_j + E(BX)E(EX)\sqrt{v}, \quad v \leq v_{desired} \quad (13)$$

gdzie zmienne losowe BX i EX są obliczane jako:

$$BX = BX_{add} + BX_{mult}RND1_n \quad (14)$$

$$EX = EX_{add} + BX_{mult}(NRND - RND2_n) \quad (15)$$

$RND1_n$ i $RND2_n$ są zmiennymi losowymi o rozkładzie normalnym z domyślną wartością średnią 0,5 i odchyleniem standardowym 0,15, specyficznymi dla n -tego pojazdu.

$NRND$ jest również zmienną losową o rozkładzie normalnym z domyślną wartością średnią 0,5 i odchyleniem standardowym 0,15. Oczekiwana wartość SDX podana jako $E(SDX)$ wynosi od 1.5 do 2.5-krotności oczekiwanej wartości ABX ($E(ABX)$), gdzie BX_{add} , BX_{mult} , EX_{add} i BX_{mult} to parametry kalibracyjne zdefiniowane przez użytkownika [30].

W modelu W-99 prędkość pojazdu podążającego wyrażona jest następującym równaniem [30]:

$$v_n(t + \Delta t) = \min \left\{ v_n(t) + 3.6 \left(CC8 + \frac{CC8 - CC9}{80} v_n(t) \right) \Delta t, v_f, 3.6 \frac{s_n(t) - CC0 - L_{n-1}}{v_n(t)} \right\} \quad (16)$$

Parametr $CC8$ jest maksymalnym przyspieszeniem pojazdu przy prędkości 0 km/h, $CC9$ jest maksymalnym przyspieszeniem przy prędkości 80 km/h.

Model ten, wyznacza prędkość pojazdu jako minimum dwóch prędkości: jednej opartej na ograniczeniach przyspieszenia i drugiej opartej na modelu podążania za liderem w stanie ustalonym.

7. Model Fritzsche

Jest to model psychofizyczny, przedstawiony przez Hansa Thomasa Fritzsche w 1994 roku [31]. W modelu zdefiniowano dwa progi związane z postrzeganą różnicą prędkości pojazdów i cztery progi związane z postrzeganą odległością [31], [32]:

- **Dodatni próg percepcji różnicy prędkości PTP**, opisany zależnością

$$PTP = k_{PTP}(\Delta x - s_{n-1})^2 + f_x \quad (17)$$

- **Ujemny próg percepcji różnicy prędkości PTN**, opisany zależnością

$$PTN = -k_{PTN}(\Delta x - s_{n-1})^2 - f_x \quad (18)$$

gdzie Δx jest odstępem pomiędzy pojazdami, s_{n-1} jest efektywną długością pojazdu poprzedzającego (obliczaną jako suma rzeczywistej długości pojazdu i minimalnego odstępu pomiędzy zatrzymanymi pojazdami), k_{PTP}, k_{PTN}, f_x są parametrami modelu. Poniżej progów PTN i PTP kierowca podążający nie dostrzega różnicy prędkości.

- **Pożądany dystans AD**, proporcjonalny do prędkości pojazdu podążającego:

$$AD = s_{n-1} + T_D v_n \quad (19)$$

gdzie T_D jest odległością czasową pomiędzy pojazdem poprzedzającym a podążającym, odpowiadającą AD i równą 1.8 s [31], v_n jest prędkością pojazdu podążającego.

- **Ryzykowny dystans AR**, proporcjonalny do prędkości pojazdu poprzedzającego v_{n-1} :

$$AR = s_{n-1} + T_r v_{n-1} \quad (20)$$

gdzie T_r jest odległością czasową odpowiadającą AR i równą 0,5 s [31].

- **Odległość bezpieczna AS**, zdefiniowana jako najmniejsza odległość pomiędzy pojazdami, przy której akceptowane jest przyspieszenie pojazdu podążającego jeżeli dystans do pojazdu poprzedzającego wzrasta:

$$AS = s_{n-1} + T_s v_n \quad (21)$$

gdzie T_s jest równe 1 s [31].


- **Odległość hamowania AB**, zależna od prędkości względnej pojazdów, równej różnicy prędkości pojazdu poprzedzającego v_{n-1} i podążającego v_n , tzn. $\Delta v = v_{n-1} - v_n$:

$$AB = AR + \frac{\Delta v^2}{\Delta b_m}, \quad \Delta b_m = |b_{min}| + a_{n-1}^- \quad \text{dla } \Delta v > 0 \text{ i } \Delta x > AD \quad (22)$$

gdzie b_{min} i a_{n-1}^- są parametrami modelu kontrolującymi maksymalne opóźnienie (hamowanie) [32].

Parametry T_D , T_r i T_s spełniają nierówność $T_D > T_s > T_r$.

Progi percepcji oraz stany modelu przedstawione są na rys. 3 [31].



Rys. 3. Progi percepcji i stany modelu Fritzscha

8. Model Gazis–Herman–Rothery (GHR)

Model GHR, jeden z najbardziej znanych i najczęściej badanych [18], [32], powstał jako rozwinięcie opracowanego przez General Motors w 1961 roku modelu znanego pod nazwą GM Car-Following Model. W przeciwieństwie do poprzednika, GHR jest modelem nieliniowym, opisanym równaniem [18], [24]:

$$a_n(t) = \alpha \frac{V_n(t)^\beta}{\Delta X_n^{front}(t - \tau_n)^\gamma} \Delta V_n^{front}(t - \tau_n) \quad (23)$$

gdzie $V_n(t)$ jest prędkością pojazdu „n” mierzona w czasie „t”, $\Delta V_n^{front}(t - \tau_n)$ jest względną prędkością pojazdu poprzedzającego (lidera), $\Delta X_n^{front}(t - \tau_n)$ jest odstępem pomiędzy pojazdem poprzedzającym a podążającym, mierzonym

w czasie $(t - \tau_n)$, τ_n jest czasem reakcji kierowcy, natomiast $\alpha > 0, \beta, \gamma$ są parametrami stałymi (współczynnikami) równania, wymagającymi ustalenia empirycznego.

Wadą modeli opartych na GM jest reagowanie na dowolnie małe zmiany w bodźcu, np. prędkości względnej. Ponadto, kierowca pojazdu podążającego pozostaje pod wpływem działań pojazdu poprzedzającego nawet wówczas, gdy odległość jest bardzo duża, a jego reakcja zanika, gdy prędkość względna wynosi zero [24].

2.2 Techniki uczenia maszynowego w Inteligentnych Systemach Transportowych

W ciągu ostatniej dekady, inteligentne systemy transportowe (ITS) stały się istotnym obiektem badań i nadal rozwijają się dynamicznie. ITS łączą informacje, komunikację i technologię transportową w celu optymalizacji zarządzania ruchem, poprawy bezpieczeństwa na drogach, zwiększenia efektywności sieci transportowych oraz usprawnienia zarządzania publicznym transportem. Istotnym czynnikiem wpływającym na jakość funkcjonowania ITS, szczególnie w kontekście kontroli ruchu, są informacje o natężeniu ruchu, zarówno długoterminowe, jak i krótkoterminowe. Ze względu na stochastyczną i nieliniową naturę zjawiska ruchu drogowego, dokładne jego prognozowanie w czasie rzeczywistym jest bardzo ważną funkcją ITS [33], [34] i pozostaje trudnym zadaniem [35]. Dotychczas stosowane metody opierają się głównie na liniowych i płytkich modelach uczenia maszynowego do prognozowania przepływu ruchu. Te metody nie potrafią poprawnie odzwierciedlić nieliniowości i probabilistycznych cech zjawisk, chociaż potrafią reagować na zmiany sezonowe [36], [37]. W ostatnich latach pojawiły się udane alternatywne próby prognozowania ruchu oparte na głębokich metodach uczenia maszynowego [35], [38]–[40] oraz metodach opartych na kombinowaniu różnych modeli, takich jak modelu Autoregressive Integrated Moving Average (ARIMA) i modelu Long Short-Time Memory (LSTM) [41], filtry Kalmana oraz ARIMA [42]. W celu poprawy dokładności prognozowania stosowane są również bardziej złożone strategie, takie jak połączone użycie Light Gradient Boosting Machine (LightGBM) oraz Gated Recurrent Unit (GRU) z modelem prognozowania Seasonal Autoregressive Integrated Moving Average (SARIMA) oraz GRU, który uwzględnia periodyczność zjawisk związanych z ruchem drogowym [43]. Pomimo postępów w dziedzinie sztucznej inteligencji i uczenia maszynowego, nie należy podważać znaczenia tradycyjnych metod statystycznych, np. wspomnianych już ARIMA czy SARIMA.

Do często spotykanych w publikacjach należą metody prognozowania szeregów czasowych GRU, LSTM NNs [44] oraz składowe autoenkodery (Stacked Auto-Encoder - SAE) [35]. W przypadkach dużych, złożonych modeli ruchu, standardową praktyką jest łączenie sieci neuronowych rekurencyjnych z grafem ruchu [45], [46]. Metoda ta

pozwala na uwzględnienie wpływu ruchu obecnego na sąsiednich drogach. Jest ona szczególnie skuteczna przy modelowaniu dużych, rozgałęzionych sieci drogowych, występujących np. w dużych obszarach metropolitalnych [45], [47]–[50].

Szybki rozwój metod uczenia maszynowego znacząco zwiększył liczbę możliwych typów i konfiguracji sieci neuronowych, ale do tej pory postęp ten nie dotyczył problemu optymalizacji, rozumianej zarówno pod kątem wyboru najodpowiedniejszego modelu i jego architektury (np. liczba warstw ukrytych jest nadal wybierana arbitralnie), jak i wyboru jego parametrów wewnętrznych [44]. Jest to problem ogólny, dotyczący nie tylko prognozowania ruchu. Ze względu na lokalnie sekwencyjny charakter zjawiska ruchu, często do jego analizy wykorzystuje się wspomniane wyżej modele sieci neuronowych GRU, LSTM i składane autoenkodery (SAE) [44]. Do uruchomienia dowolnego modelu uczenia maszynowego niezbędne są dane zebrane w rzeczywistym środowisku. Dobrym i często używanym źródłem danych o ruchu drogowym jest system pomiaru wydajności Caltrans (PeMS) [51]. Symulatory ruchu drogowego mogą być pomocniczym źródłem danych, gdy dane rzeczywiste nie są dostępne lub są niewystarczające, na przykład nie obejmują wymaganego zakresu czasu.

W ciągu ostatniej dekady zaproponowano wiele różnych metod prognozowania ruchu. Początkowo proponowane metody opierały się na modelu autoregresyjnym zintegrowanym z ruchomą średnią (ARIMA). Okazało się jednak, że model ARIMA, który opiera się na relacjach liniowych, nie jest w stanie analizować nieliniowych i zmiennych w czasie relacji, które są nieodłączną cechą ruchu drogowego [39]. Ponadto, ciągły rozwój metod związanych z głębokim uczeniem w ostatnich latach doprowadził do powstania nowych propozycji, w szczególności SAE, DNN, DBN, LSTM, czy CNN-LSTM, a także metod, które są ich kombinacjami.

Jednym z wielu przykładów tego podejścia jest publikacja [39], której autorzy proponują połączenie metod CNN i LSTM (Conv-LSTM) do ekstrakcji właściwości przestrzennych i czasowych oraz model dwurdzeniowy LSTM (Bi-LSTM) do ekstrakcji periodycznych właściwości ruchu drogowego. Według autorów, proponowana metoda daje lepsze wyniki niż inne metody wymienione w porównaniu. Szczególnie niekorzystnie wypadły metody ARIMA i SAE. Warto również zauważyć, że jakość prognozy prezentowanego rozwiązania znacząco zwiększyło dodanie modułu Bi-LSTM.

Nieco odmiennym podejściem do problemu przestrzennej analizy ruchu wykazują Yaguang Li i in. [52]. Autorzy sugerują modelowanie ruchu jako procesu dyfuzji na skierowanym grafie. Proponują sieć neuronową o rekurencyjnym splocie dyfuzji (DCRNN) do prognozowania ruchu drogowego. Struktura ta reprezentuje podejście całościowe i uwzględnia przestrzenne oraz czasowe warunki ruchu drogowego. Według autorów, eksperymenty wykazały wyraźną przewagę DCRNN nad innymi aktualnymi metodami.

Ugruntowaną pozycję wśród technik stosowanych do analizy i predykcji ruchu

drogowego mają metody LSTM. L. Mou i in. [53] prezentują wyniki badania wpływu zmienności czasowej na wyniki prognozowania LSTM. Proponowane ulepszenie uwzględnia wspomnianą zmienność i wprowadza metodę T-LSTM. Autorzy korzystają również z tej metody do rozwiązania problemu brakujących danych. Wyniki uzyskane w eksperymentach potwierdzają wysoką skuteczność proponowanej metody.

Nowa praca, opublikowana w kwietniu 2023 roku, proponuje hybrydowy model STFSA-CNN-GRU do krótkoterminowej prognozy prędkości ruchu drogowego [54]. Ten model eliminuje ograniczenia pojedynczej architektury i zapewnia dobrą dokładność i stabilność dla wielokrotnych prognoz.

Trudności związane z prognozowaniem ruchu drogowego zostały podkreślone w artykule przeglądowym z czerwca 2022 roku [55]. Autorzy artykułu wskazują na złożoność zależności przestrzennych i czasowych, dynamikę zależności czasowych oraz wpływ czynników zewnętrznych, takich jak warunki pogodowe i zdarzenia drogowe, jako na wyzwania. Według autorów, publikacja jest pierwszym kompleksowym przeglądem technik obecnie używanych do prognozowania ruchu drogowego opartego na głębokim uczeniu maszynowym. Przegląd pokazuje, że pod względem modelowania przestrzennego, dominują metody CNN oraz oparte na wielomianach Czebyszewa. Z kolei modelowanie parametrów czasowych najczęściej wykorzystuje sieci RNN, w tym warianty tych sieci, a mianowicie LSTM [56], [57] lub GRU. Taka struktura powtarza się we wszystkich obszarach prognozowania ruchu drogowego, tj. prognozowania przepływu, prędkości pojazdów, zapotrzebowania, czasu podróży i zajętości. Praca ta dobrze wskazuje na złożoność technik modelowania obecnie używanych do badania ruchu drogowego, który jest również bardzo złożonym zjawiskiem.

B. Ghosh i in. [58] proponują jednowymiarowy strukturalny model szeregów czasowych (STM), który jest używany do opracowania ekonomicznego i obliczeniowo prostego algorytmu wielowymiarowego modelu czasowego. W metodologii STM różne składowe zbioru danych szeregów czasowych, takie jak trend, sezonowość, składniki cykliczne i kalendarzowe, mogą być modelowane oddzielnie. Wyniki wskazują, że proponowany algorytm prognozowania stanowi praktyczne podejście do prognozowania w czasie rzeczywistym przepływu ruchu na wielu skrzyżowaniach w miejskiej sieci transportowej.

Techniki uczenia głębokiego są również wykorzystywane w rozwiązaniach do śledzenia i rekonstrukcji trajektorii ruchu pojazdów. Lunlin Fei i in. [59] wykorzystują techniki CNN do analizy obrazów z wielu kamer w celu identyfikacji i lokalizacji obiektów, w tym pieszych.

Rozwiązanie oparte na głębokich sieciach neuronowych (DNN) jest omówione w publikacji [60]. Autorzy proponują sześciowarstwową DNN do długoterminowej prognozy ruchu na podstawie danych historycznych oraz zestawu współczynników definiujących kontekst warunków ruchu drogowego, takich jak dzień tygodnia,

pogoda i pora roku. Podstawowym założeniem prezentowanej metody jest silna korelacja przepływu strumienia pojazdów z początkowymi i końcowymi punktami czasowymi krótkiego okresu obserwacji, wraz z czynnikami kontekstowymi. Przyjęcie takiego założenia umożliwia wydobycie zależności między wartościami przepływu ruchu w danym przedziale czasowym z danych historycznych oraz kombinacji czynników kontekstowych.

Istotnym aspektem analizy ruchu drogowego jest prognozowanie ryzyka wypadków. P. Trirat i in. [61] proponują sieci splotowe wielowymiarowego grafu do prognozowania ryzyka wypadków drogowych (MG-TAR). Prezentowane podejście próbuje rozwiązać dwa nietrywialne problemy: zrozumienie i wywodzenie statystyk dotyczących niebezpiecznej jazdy na podstawie klasyfikacji opartej na regułach oraz modelowanie jednoczesnych statycznych i dynamicznych grafów reprezentujących warunki ruchu drogowego. Ciekawym zastosowaniem głębokich sieci splotowych (CNN) jest metoda prezentowana w publikacji [62]. Polega ona na analizie dużych sieci transportowych opartej na generowaniu, za pomocą CNN, obrazu graficznego zawierającego informacje o ruchu w analizowanej sieci transportowej.

Propozycję metody prognozowania ruchu na podstawie niepełnych danych, opartą na wykorzystaniu sieci neuronowych o architekturze wykorzystującej procesy Markova na grafach - sieć Markova na grafie (GMN) przedstawiono w [63]. Rozszerzeniem tej metody poprzez dodanie operacji składania grafów spektralnych jest druga metoda proponowana przez autorów, nazwana "siecią Markova na grafie spektralnym" (SGMN). Według autorów publikacji, obie metody, GMN i SGMN, osiągają dobre wyniki prognozowania pod względem dokładności i wydajności. Odminną metodę prognozowania na podstawie niepełnych danych przedstawiono w [64]. Polega ona na wykorzystaniu bazującego na grafie przestrzenno-czasowym autoenkodera połączonego ze strukturą enkoder-dekoder. Obszerny przegląd i porównanie stosowanych metod prognozowania ruchu zawarty jest w publikacji [65]. Wykorzystanie modeli dwukierunkowych LSTM (BiLSTM) przedstawiono w [66]. Opracowane modele krótkoterminowego prognozowania ruchu BiLSTM zostały przetestowane na podstawie danych z kalibrowanego modelu mikrosymulacji.

Istotnym pomysłem jest zastosowanie metod głębokich sieci neuronowych do "prognozowania wstecznego", tj. odtwarzania warunków istniejących przed kolizją poprzez analizę uszkodzeń i deformacji pojazdów zaangażowanych w wypadek. Wyniki badań w tym kierunku zaprezentowano w [67] i [68]. W pierwszym przypadku eksperymenty przeprowadzono za pomocą algorytmu trzech sieci neuronowych (3NN) na danych syntetycznych, w drugim wykorzystana została teoria wariacyjnego uczenia bayesowskiego i architektura sieci neuronowej typu Feed-forward do "prognozowania odwrotnego". Podobnie jak w [67], eksperymenty przeprowadzono na podstawie danych syntetycznych. Rozwój metod i algorytmów, które pozwalają na rekonstrukcję warunków przedkolizyjnych na podstawie wyników kolizji, ma duże znaczenie w analizie wypadków drogowych dla

projektantów pojazdów i może pomóc systemom ITS w procesie zapobiegania wypadkom poprzez przewidywanie zdarzeń na podstawie warunków przedkolizyjnych, zapamiętanych przez algorytmy AI.

Jak pokazuje powyższy krótki przegląd, techniki uczenia maszynowego odgrywają kluczową rolę w rozwoju i wdrożeniu inteligentnych systemów transportowych. Obecnie stosuje się wiele różnych technik, dobieranych odpowiednio do zagadnień będących przedmiotem analiz. Powszechne jest również jednoczesne stosowanie różnych technik i budowanie modeli mieszanych, szczególnie w przypadku bardziej złożonych problemów, np. analizy ruchu drogowego z jednoczesnym uwzględnieniem jego rozkładu przestrzennego.

Do najczęściej stosowanych technik uczenia maszynowego obecnie należą:

1. Sieci neuronowe:

Sieci neuronowe, w szczególności głębokie sieci neuronowe, są powszechnie stosowane w inteligentnych systemach transportowych. Są one używane do wielu różnych zadań, takich jak prognozowanie natężenia ruchu, prognozowanie prędkości pojazdów [69], rozpoznawanie obiektów na obrazach z kamer drogowych, przewidywania czasu podróży czy budowania modeli mikroskopowych typu car-following [70], [71].

2. Metody szeregów czasowych:

Metody szeregów czasowych, takie jak ARIMA [72], [73], SARIMA czy oparte na LSTM wykorzystuje się często w pracach związanych z przewidywaniem natężenia ruchu i czasu podróży. Metody te w dużej mierze są podzbiorem pkt.1 (z wyjątkiem tradycyjnych metod statystycznych, takich jak ARIMA czy SARIMA), ze względu na ich szczególne znaczenie zostały wymienione osobno.

3. SVM (Support Vector Machines):

SVM są często stosowane do klasyfikacji danych w inteligentnych systemach transportowych, na przykład do rozpoznawania typów pojazdów czy do wykrywania anomalii w danych o ruchu drogowym.

4. Drzewa decyzyjne i lasy losowe:

Techniki te są używane do modelowania złożonych zależności w danych, na przykład do identyfikowania różnych typów ruchu drogowego, lub do przewidywania natężenia ruchu.

5. Uczenie maszynowe z wzmocnieniem:

Techniki te stosowane są w kontekście optymalizacji i sterowania, na przykład do optymalizacji sygnalizacji świetlnej, czy do sterowania flotą pojazdów autonomicznych [74].

6. Algorytmy genetyczne:

Są one stosowane do optymalizacji i szukania rozwiązań w problemach

złożonych i wielowymiarowych, takich jak optymalizacja tras czy harmonogramów transportowych.

Wybrane spośród przedstawionych wyżej modeli zostaną zastosowane do przeprowadzenia eksperymentów opisanych w następnym rozdziale niniejszej rozprawy, t.j. w rozdziale trzecim.

Rozdział 3

Opis eksperymentów i analiza rezultatów

Do przeprowadzenia eksperymentów związanych z symulacją ruchu drogowego zastosowany został program o nazwie Vissim [75]. Jest to profesjonalne narzędzie stosowane w wielu krajach świata. Przed przeprowadzeniem symulacji niezbędne jest skalibrowanie modeli, które są wykorzystywane w toku mikroskopowej symulacji ruchu drogowego. Metody kalibracji modeli programu Vissim opisane są w wielu źródłach, np. [29], [76], [77]. W przeprowadzonych eksperymentach wykorzystano obydwa modele Wiedemanna, tzn. W-74 oraz W-99.

Kalibracja modelu W-74 wymaga zdefiniowania następujących parametrów [15]:

ax [m] - Odstęp przy zatrzymaniu: Średni pożądany odstęp pomiędzy dwoma stojącymi pojazdami.

bx_{add} [m] - Dodatkowa część bezpiecznego dystansu.

bx_{mult} [m] - Multiplikatywna część bezpiecznego dystansu.

Pożądany bezpieczny dystans $d = ABX$ obliczany jest z zależności (24):

$$d = ax + (bx_{add} + bx_{mult}z)\sqrt{v} \quad (24)$$

gdzie v jest prędkością pojazdów w m/s, z jest zmienną przyjmującą wartości z przedziału $\langle 0, 1 \rangle$, o dystrybucji normalnej wokół 0,5 i standardowej dewiacji 0,15.

W eksperymentach przyjęto wartości domyślne programu, sugerowane także w literaturze ([15], [78]), tzn. $ax = 2$ m, $bx_{add} = 2$ m, $bx_{mult} = 3$ m oraz $z = 0,5$.

Do kalibracji modelu W-99 Vissim udostępnia następujące parametry [15]:

- | | |
|-----------------|--|
| CC0 [m] | - Odstęp przy zatrzymaniu: Średni pożądany odstęp pomiędzy dwoma stojącymi pojazdami. |
| CC1 [s] | - Odległość od poprzedzającego pojazdu: Odległość w sekundach, jaką chce zachować kierowca przy danej prędkości. |
| CC2 [m] | - oscylacja dystansu w trybie podążania. |
| CC3 [s] | - próg wejścia w tryb podążania. |
| CC4 [m/s] | - ujemny próg trybu podążania. |
| CC5 [m/s] | - dodatni próg trybu podążania. |
| CC6 [1/(m × s)] | - Wpływ odległości na oscylację prędkości podczas procesu jazdy za poprzednikiem: |

CC6 = 0: Oscylacja prędkości nie zależy od odległości.

CC6 > 0: Wzrostem odległości prowadzą do większych zmian prędkości

- CC7 [m/s²] - oscylacja przyspieszenia.
- CC8 [m/s²] - przyspieszenie od $v = 0$ km/h.
- CC9 [m/s²] - przyspieszenie od $v = 80$ km/h.

Do kalibracji modeli zastosowane zostały zalecenia przedstawione w [78], przyjęto więc następujące wartości parametrów kalibracyjnych:


CC0:	1,5 m
CC1:	0,9 s
CC2:	4 m
CC3:	-8 s
CC4:	-0,35 m/s
CC5:	0,35 m/s
CC6:	11,44 1/(m x s)
CC7:	0,25 m/s ²
CC8:	3,5 m/s ²
CC9:	1,5 m/s ²

Eksperyment 1

Sprawdzenie wpływu sposobu stopniowania ograniczenia prędkości na czas przejazdu testowego odcinka drogi

Duże ograniczenia prędkości na odcinkach dróg mogą prowadzić do zwiększenia ryzyka wypadków, ponieważ liczniejsza grupa kierowców będzie skłonna do podejmowania ryzyka przekroczenia ograniczenia ze względu na postrzeganą stratę czasu. Celem przeprowadzonego eksperymentu było sprawdzenie, czy czas przejazdu testowego odcinka drogi może być optymalizowany poprzez dobór sposobu stopniowania ograniczenia prędkości pojazdów. Motywacją tego eksperymentu wynikała także z praktycznej potrzeby określenia prędkości wyświetlanej przez skonstruowane znaki drogowe zmiennej treści, które opisano w rozdziale 4.

Jako testowy odcinek drogi zaproponowany został model o topologii pokazanej na rys. 4. Model ten składa się z pięciu odcinków dróg o identycznej długości, różniących się liczbą zainstalowanych znaków zmiennej treści. Droga numer 5 nie zawiera żadnych ograniczeń prędkości (w dozwolonym zakresie, zdefiniowanym na początku wszystkich odcinków) i jest odcinkiem referencyjnym.



Rys. 4. Model odcinków dróg przyjęty w symulacji czasu przejazdu

Przyjęto następujące oznaczenia:

- V_{in} - dopuszczalna prędkość w zależności od klasy drogi
- $TL[m]$ - długość odcinka testowego do pomiaru czasu, wyrażona w metrach
- S - odległość między znakami drogowymi o zmiennej treści, wyrażona w metrach (przyjęto, że jest taka sama dla wszystkich znaków)
- $L[m]$ - całkowita długość modelowanych odcinków dróg, wyrażona w metrach
- G - droga główna
- GP - droga główna ruchu przyspieszonego
- S - droga ekspresowa
- $W-74, W-99$ - modele zachowań kierowców (modele 74 i 99 Wiedemanna)

Symulacje przeprowadzono dla trzech klas technicznych dróg określonych w przepisach krajowych w Polsce: G , GP i S . Klasy te różnią się natężeniem ruchu i dopuszczalnymi prędkościami.

Eksperymenty przeprowadzono według następujących scenariuszy:

1. scenariusz nr 1:
 - $L = 1000$ m, $S = 100$ m, $TL = 600$ m
 - model kierowcy - $W-74$
 - Klasa drogi - G
 - Dozwolona prędkość maksymalna - 90 km/h
 - Natężenie ruchu - 246 p/h (pojazdów na godzinę)
 - Limity prędkości : $V1a = 60$ km/h, $V1b = 50$ km/h, $V1c = 50$ km/h

V2a = 70 km/h, V2b = 60 km/h, V3 = 70 km/h

Czas symulacji - 3 h

2. scenariusz nr 2:

L = 1000 m, S = 200 m, TL = 600 m

model kierowcy - W-99

Klasa drogi - GP

Dozwolona prędkość maksymalna - 90 km/h

Natężenie ruchu - 431 p/h (pojazdów na godzinę)

Limity prędkości : V1a = 60 km/h, V1b = 50 km/h, V1c = 40 km/h

V2a = 80 km/h, V2b = 60 km/h, V3 = 80 km/h

Czas symulacji - 3 h

3. scenariusz nr 3:

L = 2000 m, S = 200 m, TL = 1600 m

model kierowcy - W-99

Klasa drogi - S

Dozwolona prędkość maksymalna - 120 km/h

Natężenie ruchu - 1049 p/h (pojazdów na godzinę)

Limity prędkości : V1a = 80 km/h, V1b = 60 km/h, V1c = 60 km/h

V2a = 90 km/h, V2b = 80 km/h, V3 = 100 km/h

Czas symulacji - 3 h

4. scenariusz nr 4:

L = 2000 m, S = 300 m, TL = 1600 m

model kierowcy - W-99

Klasa drogi - S

Dozwolona prędkość maksymalna - 120 km/h

Natężenie ruchu - 1049 p/h (pojazdów na godzinę)

Limity prędkości : V1a = 80 km/h, V1b = 60 km/h, V1c = 60 km/h


V2a = 90 km/h, V2b = 80 km/h, V3 = 100 km/h

Czas symulacji - 3 h


W zależności od badanej klasy drogi w symulacji wykorzystano dwa modele zachowań kierowców: Model Wiedemanna 74 [76], [79] dla klasy G oraz Model Wiedemanna 99 [29] dla klas GP i S. Przyjęto, że maksymalne opóźnienie w normalnych warunkach ruchu wynosi od 3,2 m/s² do 3,5 m/s² [80], natomiast maksymalne opóźnienie podczas hamowania awaryjnego wynosi około 1 g, tj. 9,81 m/s² [81].

Wyniki pomiarów czasów przejazdu odcinków testowych znormalizowano względem wartości średniej uzyskanej dla drogi nr 5 (droga referencyjna), na której ruch odbywał się bez przeszkód. Wyniki eksperymentów pomiaru czasu podróży pokazano na rys. 5.

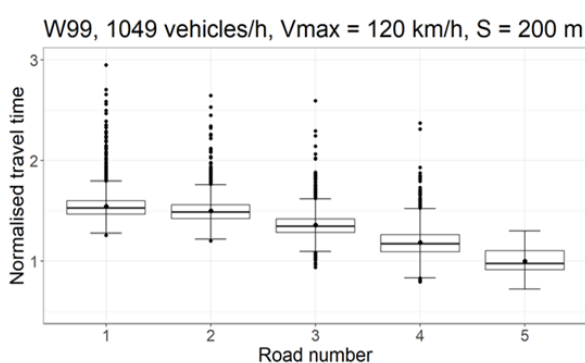





(a) Droga G, $L = 1$ km, $TL = 600$ m



(b) Droga GP, $L = 1$ km, $TL = 600$ m



(c) Droga S, $L = 2$ km, $TL = 1600$ m



(d) Droga S, $L = 2$ km, $TL = 1600$ m

Rys. 5. Znormalizowany czas podróży w zależności od natężenia ruchu i odległości znaków drogowych.

Eksperymenty wykazały, że stopniowanie ograniczenia prędkości powoduje skrócenie czasu przejazdu przez odcinek testowy. Tendencja ta jest niezależna od kategorii drogi, chociaż można również zauważyć, że zwiększone natężenie ruchu wiąże się z zakłóceniami płynności ruchu. Zwiększenie odległości między znakami spowodowało zauważalne wydłużenie czasu podróży.

Eksperymenty związane z pomiarem czasu przejazdu wykazały wyraźny wpływ zarówno wielokrotnego stopniowania ograniczeń prędkości, jak i odległości między znakami na badany parametr, tzn. czas przejazdu testowego odcinka drogi.


Najbardziej uporządkowaną sytuację można zaobserwować na rys. 5 (a). Niskie natężenie ruchu i stosunkowo niezbyt wysokie prędkości powodują, że punkty pomiarowe ustawiają się regularnie w jednej linii. Wzrost natężenia ruchu do 431 pojazdów na godzinę przy zachowaniu prędkości (rys. 5 (b)), tj. 90 km/h, nie spowodował istotnych zmian. Można jednak zaobserwować pierwsze oznaki zaburzeń na drodze nr 1, przejawiające się zwiększoną liczbą punktów odstających. Podwojenie natężenia ruchu i zwiększenie prędkości do 120 km/h, jak na rys. 5 (c) i (d), powoduje wyraźny wzrost

liczby pojazdów, dla których czas przejazdu jest znacznie dłuższy. Przejawem tego jest tworzenie się kolejek. Można również zauważyć, porównując rys. 5 (c) i (d), że zwiększenie odległości między znakami drogowymi powoduje wyraźne wydłużenie czasu przejazdu. W normalnych warunkach drogowych oczywiste wydaje się zakwalifikowanie wprowadzenia jednego dużego ograniczenia prędkości, np. ze 120 km/h do 30 km/h, jako postępowania błędnego. Należy jednak zauważyć, że jest to częsta sytuacja w przypadku np. kolizji drogowej. Wprowadzenie adaptacyjnych systemów lokalnych, zdolnych do wieloetapowego zmniejszania prędkości na odcinkach narażonych na wyjątkowo duże ryzyko nagłego zakłócenia ruchu, mogłoby znacznie poprawić bezpieczeństwo. Powyższe eksperymenty zostały opisane w publikacji [82].

Eksperyment 2

Sprawdzenie wpływu odległości pomiędzy znakami zmiennej treści na wariację prędkości pojazdów


W celu przeprowadzenia eksperymentów przygotowano scenariusz symulacji na fragmencie Drogi Kaszubskiej, w pobliżu szczytu Wieżyca, położonej w województwie pomorskim. Jest to dwukierunkowy, lokalny i pozamiejski odcinek drogi z dwoma pasami ruchu (rys. 6). Odległość pomiędzy znakami drogowymi, aktywnie kontrolującymi prędkość na odcinkach dróg, jest kolejnym istotnym elementem rozstrzygającym o efektywności stosowania rozwiązania opartego na skonstruowanych znakach zmiennej treści, opisanych w rozdziale 4.



Rys. 6. Sieć drogową odpowiadającą scenariuszowi przeprowadzonych symulacji

Rozważany odcinek miał długość około 2,3 kilometra i składał się głównie z prostych

odcinków z kilkoma zakrętami. Lokalizację znaków ograniczenia prędkości i punktów pomiarowych pokazano na rys. 7.



Rys. 7. Lokalizacja znaków ograniczenia prędkości i punktów pomiarowych.

Maksymalna dozwolona prędkość wynosi 90 km/h, a natężenie ruchu nie przekracza 380 p/h. Według polskiej dyrekcji dróg 95% ruchu stanowią samochody osobowe, a 5% ciężarowe. Wartości te zostały użyte w symulacji. W eksperymentach uwzględniono jedynie swobodny przepływ pojazdów. Przyjęte wielkości w zasadzie uniemożliwiają uwzględnienie mechanizmów takich jak grupowanie pojazdów, jednak w bardziej ogólnym przypadku konieczne byłoby uwzględnienie zarówno obserwowanej skłonności pojazdów do tworzenia grup, jak i strategii wykorzystujących to zjawisko [83] [84].

Według [85] zmiana prędkości przekraczająca 20 km/h należy do grupy "złych praktyk", jednak w Polsce przepisy dopuszczają taką zmianę, jeśli prędkość projektowana nie przekracza 90 km/h, co ma miejsce w omawianym przypadku.

W eksperymencie zastosowano model W-74. Ponieważ rzeczywiste dane dla odcinka testowego nie były dostępne, podobnie jak w poprzednim eksperymencie, model został który został skalibrowany tak, jak w eksperymencie 1.

Przyjęto, że podczas hamowania prędkość jest zmniejszana równomiernie. Opóźnienia zależy jednak od warunków pogodowych i drogowych, takich jak śliskość, zakrzywienie lub stromość, i nie powinno przekraczać maksymalnej wartości umożliwiającej hamowanie bez poślizgu. Ponadto, w normalnych warunkach drogowych opóźnienie nie powinno przekraczać wartości uznawanej za komfortową.

Zgodnie z AASHTO, że ze względu na odczuwany przez większość kierowców dyskomfort, opóźnienie nie powinno przekraczać niż około 3,4 m/s² [86]. Do kalibracji programu Vissim przyjęto wartości zalecane w [78], tzn. 3,0 m/s² dla samochodów osobowych i 1,5 m/s² dla samochodów ciężarowych.

Zakładając, że opóźnienie a ma stałą wartość, odległość przebyta przez pojazd podczas zmiany prędkości z v_0 na v_1 (w m/s) można opisać równaniem:

$$d = v_0 t_r + \frac{v_0^2 - v_1^2}{2a} \quad (25)$$

gdzie t_r jest czasem reakcji kierowcy. Zgodnie z [87], można założyć, że $t_r = 2,5$ s.

Dla wygody, aby prędkości mogły być podane w km/h, (25) można przekształcić do postaci:

$$d = 0,278V_0 t_r + 0,039 \frac{V_0^2 - V_1^2}{2a} \quad (26)$$

Wartość a w obu równaniach jest podana w m/s².

Powyższe równania mają zastosowanie tylko do ruchu wzdłuż trajektorii znajdującej się na płaszczyźnie poziomej, wystarczającej do zilustrowania metody.

Maksymalna prędkość pojazdu na zakręcie ograniczona jest dwoma czynnikami: siłami przyczepności oraz akceptowalnym poziomem dyskomfortu powodowanego przez reakcję odśrodkową podczas jazdy po łuku drogi.

Pierwsze z wymienionych ograniczeń sprowadza się do wymagania na współczynnik tarcia bocznego pomiędzy kołami pojazdu a nawierzchnią drogi. Podstawowa zależność współczynnika tarcia bocznego f od prędkości V opisana jest równaniem (27), regulującym działanie pojazdu na łuku drogi [87]:

$$f + 0,01e = \frac{V^2}{127R} \quad (27)$$

gdzie:

V = prędkość pojazdu w km/h

f = współczynnik tarcia bocznego

e = współczynnik przewyższenia jezdni, w procentach

R = promień łuku mierzony do środka ciężkości pojazdu, w [m].

Z (27) można uzyskać następującą zależność prędkości pojazdu od promienia łuku drogi:

$$V = \sqrt{127R(f + 0,01e)} \quad (28)$$

Ponieważ dokładne parametry nawierzchni, tj. e i f , nie były znane, do dalszych obliczeń wykorzystano wartości sugerowane w [87]:

- $e = 6\%$
- $(0,01e + f) = 0,34$

Z (28) otrzymujemy wówczas maksymalną prędkość na łuku o promieniu 25 m i suchej nawierzchni: $V = 33$ km/h.

Drugim parametrem ograniczającym prędkość pojazdu na łuku jest dopuszczalna wartość przyspieszenia dośrodkowego (b_{acc}) odpowiadająca odczuwanej przez kierowcę

i pasażerów reakcji odśrodkowej:

$$V = \sqrt{127R\left(\frac{b_{acc}}{g} + 0,01e\right)} \quad (29)$$

Literatura podaje różne wartości akceptowalnych progów odczuwanej reakcji odśrodkowej. Według [88] wartość b_{acc} powinna być przyjmowana z zakresu 0,4...1,3 m/s². Według [87] wartość ta wynosi około 2,4 m/s² dla prędkości 30 km/h. Autorzy artykułów [88] i [89] podają limit dyskomfortu wynoszący odpowiednio 2,6 m/s² i 5 m/s² (dla prędkości 40-50 km/h). Ponieważ wartości podane przez AASHTO [87] zostały określone na podstawie badań przeprowadzonych w latach trzydziestych XX wieku, w literaturze pojawiają się sugestie, aby dostosować je do współczesnych realiów. Najnowsze badania sugerują wyższe wartości, np. w [89]. Do eksperymentów przyjęto, że $b_{acc} = 3$ m/s². Z równania (29) otrzymujemy $V = 34$ km/h.

W tym przypadku uzyskaliśmy bardzo zbliżone wartości, więc przyjęto limit 30 km/h dla suchej nawierzchni.

Dla wartości początkowej $V_0 = 60$ km/h, wartości końcowej $V_1 = 30$ km/h i opóźnienia $a = 1,5$ m/s² (dla pojazdów ciężarowych), (26) daje odległość między znakiem ograniczenia prędkości a początkiem łuku drogi wynoszącą 77 m.

Tarcie dostępne na większości mokrych nawierzchni i możliwości większości układów hamulcowych pojazdów mogą zapewnić tarcie hamowania przekraczające prędkość zwalniania 3,4 m/s² [87].

W przypadku śliskiej jezdni przyjmuje się, że współczynnik tarcia wynosi $f = 0,15$. Równanie (28) daje wówczas $V = 25,6$ km/h. Ograniczenia prędkości (rys. 7) zostały zmienione dla tego przypadku z 30 km/h na 25 km/h i z 60 km/h na 50 km/h.

Celem eksperymentu było sprawdzenie zależności wariancji prędkości pojazdów na kontrolowanym odcinku drogi od lokalizacji znaków ograniczenia prędkości i odległości między nimi. Jak wspomniano wcześniej, badania potwierdzają, że zarówno wzrost prędkości, jak i wzrost wariancji prędkości pojazdów powoduje znaczny wzrost liczby wypadków [90]. Z tego powodu zmienność prędkości pojazdów jest istotnym parametrem, a poszukiwanie metod jej ograniczania jest jak najbardziej uzasadnione.

Uzyskane wyniki będą stanowiły podstawę do opracowania algorytmu sterowania autonomicznymi znakami drogowymi o zmiennej treści.

Badania zostały zaprojektowane jako seria eksperymentów obejmujących symulację ruchu na drodze pokazanej na rys. 7. Rejestrowanymi parametrami były prędkości pojazdów, przyspieszenia, odległości między pojazdami oraz czas jazdy. Eksperymenty przeprowadzono dla trzech odległości d : 75 m, 100 m i 150 m oraz dla dwóch warunków nawierzchni: suchej i oblodzonej.


Wszystkie scenariusze zakładały rozdzielczość symulacji wynoszącą 20 kroków czasowych na każdą sekundę symulacji (tj. 0,05 s) i czas trwania symulacji wynoszący trzy

godziny. Przetwarzanie danych uzyskanych z symulacji i obliczenia zostały wykonane w środowisku języka R.

Pierwsza część przedstawionych wyników dotyczy suchej nawierzchni. Ponieważ jednak krytycznym elementem drogi pokazanej na rys. 7 jest ostry zakręt, główny nacisk zostanie położony na dane uzyskane z punktów pomiarowych 5 (początek łuku drogi), 6 (środek łuku drogi) i 7 (koniec łuku drogi).


Rys. 8, 9 i 10 przedstawiają prędkości pojazdów, mierzone w punktach pomiarowych dla trzech wartości odległości d (rys. 7) znaku ograniczenia prędkości od początku łuku drogi.

Rys. 8 pokazuje znaczne zróżnicowanie prędkości pojazdów na początku łuku drogi. Grupa pojazdów, stanowiąca wartości odstające w punkcie pomiarowym 5, porusza się ze zbyt dużą prędkością. W punkcie pomiarowym 6 (połowa długości łuku drogi) grupa ta jest zauważalnie mniej liczna i prawie zanika na końcu łuku.




Rys. 8. Prędkości pojazdów dla dystansu $d = 75$ m.

Stosunkowo wysoki odsetek pojazdów porusza się ze zbyt dużą prędkością podczas wchodzenia w zakręt (wartości odstające w punkcie pomiarowym 5). W punkcie 6 (połowa długości łuku drogi) pojazdów tych jest wyraźnie mniej i niewiele już na końcu łuku, w punkcie pomiarowym nr 7.



Rys. 9. Prędkości pojazdów dla dystansu $d = 100$ m.

Zauważalnie mniej pojazdów porusza się ze zbyt dużą prędkością podczas wchodzenia w zakręt (wartości odstające w punkcie pomiarowym 5) niż na rys. 8, podobnie w środku i na końcu łuku drogi.




Rys. 10. Prędkości pojazdów dla dystansu $d=150$ m.

Tylko niewielki ślad pojazdów poruszających się ze zbyt dużą prędkością jest widoczny podczas wchodzenia w zakręt (wartości odstające w punkcie pomiarowym 5). Zjawisko to nie występuje już w środku (punkt pomiarowy 6) i na końcu zakrętu (punkt pomiarowy 7).




Na rys. 11÷19 przedstawiono rozkład prędkości dla poszczególnych konfiguracji i nawierzchni suchej.




Rys. 11. Rozkład prędkości pojazdów w punkcie pomiarowym MP5 i odległości d=75m.

Widoczna jest grupa pojazdów przekraczających 85% kwantyla prędkości.




Rys. 12. Rozkład prędkości pojazdów w punkcie pomiarowym MP6 dla dystansu d=75m.

Zarówno liczba pojazdów jadących zbyt szybko, jak i maksymalna zmierzona prędkość są niższe niż na rys. 11.




Rys. 13. Rozkład prędkości pojazdów w punkcie pomiarowym MP7 dla dystansu $d=75\text{m}$.

Zarówno liczba pojazdów jadących zbyt szybko, jak i maksymalna zmierzona prędkość są niższe niż na rys. 11 i 12.



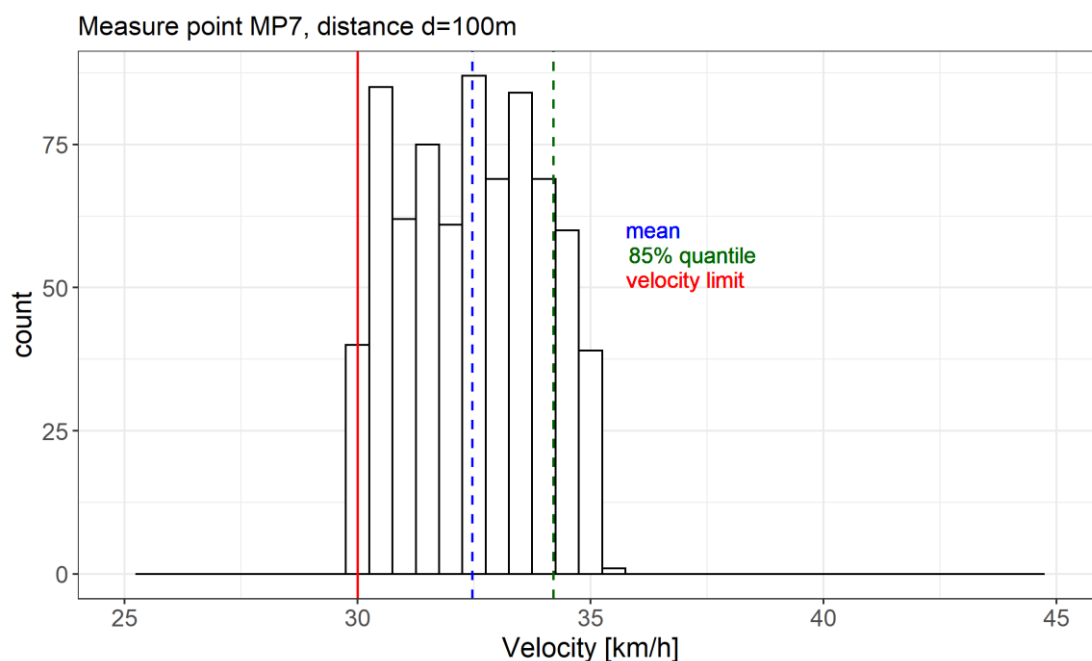
Rys. 14. Rozkład prędkości pojazdów w punkcie pomiarowym MP5 i odległości $d=100\text{m}$.

Widoczny jest efekt zwiększania odległości d . Zarówno liczba pojazdów jadących zbyt szybko, jak i maksymalna zmierzona prędkość są niższe niż na rys. 11, tj. w tym samym punkcie pomiarowym.




Rys. 15. Rozkład prędkości pojazdów w punkcie pomiarowym MP6 i odległości $d=100\text{m}$.

Wpływ zwiększenia odległości d jest nadal widoczny, choć nie tak znaczący jak na wejściu w zakręt. Zarówno liczba pojazdów jadących zbyt szybko, jak i maksymalna zmierzona prędkość są niższe niż na rys. 12.




Rys. 16. Rozkład prędkości pojazdów w punkcie pomiarowym MP7 i odległości $d=100\text{m}$.

Wpływ zwiększenia odległości d jest nadal widoczny, choć nie tak znaczący jak na wejściu w zakręt. Zarówno liczba pojazdów jadących zbyt szybko, jak i maksymalna zmierzona prędkość są niższe niż na rys. 13.




Rys. 17. Rozkład prędkości pojazdów w punkcie pomiarowym MP5 i odległości d=150m.

Liczba pojazdów poruszających się zbyt szybko i maksymalna zmierzona prędkość są niższe niż na rys. 11 i 14, tj. w tym samym punkcie pomiarowym.




Rys. 18. Rozkład prędkości pojazdów w punkcie pomiarowym MP6 i odległości d=150m.

Rys. 20 i 21 przedstawiają wariacje prędkości odpowiednio dla nawierzchni suchej




Rys. 19. Rozkład prędkości pojazdów w punkcie pomiarowym MP7 i odległości d=150m.

i śliskiej.



Rys. 20. Wariacja prędkości na łuku drogi, przypadek suchej nawierzchni.

W punkcie początkowym łuku (punkt pomiarowy 5) można zaobserwować wyraźny spadek wariacji wraz ze wzrostem odległości d. W środku zakrętu zależność jest znacznie słabsza i praktycznie niewidoczna na końcu łuku drogi (punkt pomiarowy 7).



Rys. 21. Wariancja prędkości pojazdu dla dystansu d równego 75 m, 100 m, 150 m (przypadek śliskiej nawierzchni).

Wariancja prędkości na początku i środku łuku drogi jest zauważalnie wyższa niż w przypadku suchej nawierzchni (rys. 20). Ograniczenia prędkości w poprzednich punktach są prawdopodobnie nieoptymalne.

Lokalizacja znaków drogowych ma wyraźny wpływ na zachowanie kierowców. Odległość odpowiadająca odległości teoretycznie potrzebnej samochodom ciężarowym do zmniejszenia prędkości, która zwykle jest wystarczająca dla samochodów osobowych, wydaje się zbyt krótka. Rys. 8, punkt pomiarowy 5, pokazuje, że stosunkowo duża grupa kierowców wjeżdża w zakręt ze zbyt dużą prędkością. Wartość 85% percentyla pokazana na rys. 12 wynosi 34,5 km/h. Dodatkowym negatywnym zjawiskiem jest duża wariancja prędkości na początku zakrętu (nadaj punkt pomiarowy 5). Zwiększenie odległości do 100 m przyniosło wyraźną poprawę, tj. zmniejszenie prędkości na początku zakrętu i zmniejszenie wariancji prędkości. Odległość 150 m wydaje się być bliska optymalnej. Prędkość początkowa (punkt pomiarowy 5 na rys. 10) jest niższa niż w obu poprzednich konfiguracjach, a różnica wariancji w punktach pomiarowych 5 i 7 jest najmniejsza (rys. 20). Na podstawie rys. 20 i 21 można założyć, że wariancja osiąga minimum, jeśli jej wartości wyznaczone w skrajnych punktach, tj. w punktach 5 i 7, są takie same. Należy również zauważyć (rys. 11+9), że we wszystkich przypadkach bardzo niewielka część pojazdów poruszała się z prędkością zalecaną lub mniejszą. Kolejną obserwacją jest to, że odległość d wpływa na prędkość i wariancję prędkości na początku łuku drogi. Wpływ ten jest mniejszy w środkowej części łuku, podczas gdy na końcu efekt jest praktycznie niewidoczny. Interesującą obserwacją jest, że wszystkie pojazdy zaczynają przyspieszać, ale wariancja prędkości w punkcie pomiarowym 7 jest najmniejsza i najbardziej wspólna dla wszystkich konfiguracji (rys. 11). W przypadku śliskiej nawierzchni i zmiany ograniczeń prędkości z 60 km/h na 50 km/h i z 30 km/h na 25 km/h wyniki są mniej zadowalające. Zmniejszenie prędkości na łuku drogi jest zauważalne, ale



nieznaczne, wariancja prędkości okazała się jednak wyższa (rys. 21). Bardziej szczegółowe uwagi znajdują się w podpisach rys. 8-19. Powyższe wyniki odnoszą się do konkretnej konfiguracji, więc każda próba zmiany odległości między znakami drogowymi w praktyce wymagałaby ponownego przeliczenia symulacji. Interesujące byłoby również porównanie wyników uzyskanych dla dwóch różnych modeli zachowania kierowcy, tj. modelu Wiedemanna i Inteligentnego Modelu Kierowcy (IDM), przedstawionych w publikacji [88]. Powyższe eksperymenty zostały opisane w [91]. Tendencja do przekraczania zalecanej prędkości pojazdów jest znana w literaturze i powinna być uwzględniana przy definiowaniu ograniczeń [11].

Eksperyment 3

Testowanie modeli rekurencyjnych sieci neuronowych z użyciem danych syntetycznych (inferencja)

W celu przeprowadzenia opisanych dalej eksperymentów wybrane zostały algorytmy uczące się, oparte na szeregach czasowych. Metodologia zastosowana w pierwszej fazie eksperymentów została początkowo zainspirowana publikacjami [35] oraz [44]. Testy przeprowadzono w oparciu o trzy modele uczenia maszynowego: LSTM, GRU i SAE, opisane szczegółowo w pierwszej części niniejszego paragrafu.. Intencją było porównanie efektywności szybko rozwijających się obecnie metod z dziedziny uczenia maszynowego z klasycznymi algorytmami opartymi na statystyce.


Do eksperymentów wykorzystano dwa zestawy danych:

1. Rzeczywiste dane pomiarowe dostarczone przez Kalifornijski Departament Transportu (CalTrans) na stronie internetowej Caltrans Performance Measurement System (PeMS) [51]. Korzystanie z danych PeMS wymaga pewnej ostrożności, ponieważ dość często zdarza się, że poszczególne stacje pomiarowe lub obwody nie dostarczają wiarygodnych danych pomiarowych z powodu uszkodzeń lub wyłączeń. Stan techniczny urządzeń pomiarowych i ocenę wiarygodności danych można sprawdzić na stronie internetowej PeMS.
2. Zsyntetyzowany zestaw danych został uzyskany przy użyciu oprogramowania do symulacji mikroskopowej Vissim [15].

Do treningu i walidacji modeli uczenia maszynowego wybrano dane z maja 2022 r. i podzielono je na zbiór uczący 4 377 rekordów, zawierający dane o natężeniu ruchu od 1 do 16 maja, oraz zbiór walidacyjny 1 095 rekordów, zawierający dane od 16 do 19 maja. W obu przypadkach dane były agregowane co 5 minut i pochodziły ze stacji 772903 (I210-E).

Dane testowe zostały wygenerowane przy użyciu symulatora Vissim, skalibrowanego z danymi PeMS od 1 do 7 maja.

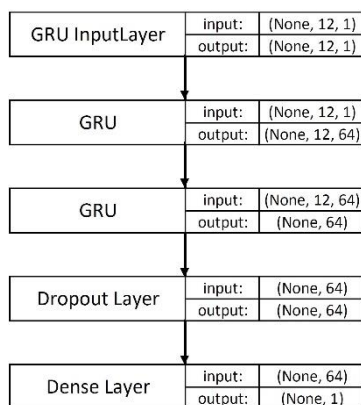
Przyjęty model LSTM w konfiguracji trójwarstwowej pokazano na rys. 22.



Rys. 22. Model LSTM

Do dalszych testów stworzono cztery modele zawierające od jednej do czterech warstw LSTM.

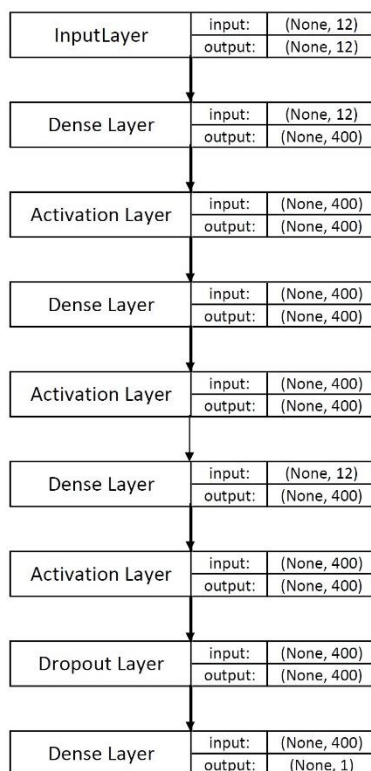
Przyjęty model GRU w konfiguracji trójwarstwowej pokazano na rys. 23.



Rys. 23. Model GRU

Podobnie jak w przypadku LSTM, stworzono cztery modele zawierające od jednej do czterech warstw GRU.

Zastosowany model SAE pokazano na rys. 24.



Rys. 24. Model SAE

Ponieważ testy pilotażowe wykazały, że w przypadku ułożonych autoenkoderów średni błąd procentowy między wartością przewidywaną a rzeczywistą dla zestawu walidacyjnego jest zwykle wyższy niż w przypadku modeli GRU i LSTM, model SAE został przetestowany tylko w konfiguracji trójwarstwowej, pokazanej powyżej. Z tego powodu więcej uwagi poświęcono testowaniu modeli opartych na sieciach rekurencyjnych niż autoenkoderów. Podobnie jak modele GRU i LSTM, model SAE został przetestowany przy użyciu danych syntetycznych, pochodzących z symulatora Vissim.

Do oceny modeli wykorzystano następujące metryki:

- `explained_variance_score`, opisana równaniem (30)

$$\text{explained variance}(y, \hat{y}) = 1 - \frac{\text{Var}(y - \hat{y})}{\text{Var}(y)} \quad (30)$$

gdzie: y - wartości rzeczywiste, \hat{y} - wartości przewidywane, $\text{Var}(y - \hat{y})$ - wariancja błędów predykcji, $\text{Var}(y)$ - rzeczywiste wartości wariancji.

- Mean Absolute Percent Error (MAPE), opisany równaniem (31)

$$\text{MAPE}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (31)$$

- Mean Absolute Error (MAE), opisany równaniem (32)

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (32)$$

- Mean Squared Error (MSE), opisany równaniem (33)

$$MSE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (33)$$

- Rooted Mean Squared Error (RMSE), opisany równaniem (34)

$$RMSE(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (34)$$

- współczynnik determinacji R^2 , opisany równaniem (35)


$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (35)$$

gdzie

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (36)$$


Wszystkie obliczenia zostały wykonane na komputerze z sześciordzeniowym procesorem Intel Core i7-6800k @ 3,40 GHz, 64 GB pamięci RAM, z kartą graficzną NVIDIA GeForce GTX 1070, z systemem MS Windows 10 Pro.

Rys. 26 przedstawia średni błąd procentowy w funkcji liczby pętli uczących dla zestawu walidacyjnego i czterech modeli LSTM, różniących się liczbą warstw wewnętrznych. Można zauważyć, że strata uczenia nie jest liniową funkcją liczby warstw i jest najmniejsza w przypadkach, gdy liczba warstw jest parzysta.



Rys. 25. Średni błąd procentowy między wartościami przewidywanymi a rzeczywistymi dla zestawu walidacyjnego czterech modeli LSTM: jedno-, dwu-, trzy- i czterowarstwowego.


Analogicznie, rys. 5 pokazuje średni błąd procentowy jako funkcję liczby pętli uczących dla zestawu walidacyjnego i czterech modeli GRU, różniących się liczbą warstw wewnętrznych.



Rys. 26. Średni błąd procentowy między wartościami przewidywanymi a rzeczywistymi dla zestawu walidacyjnego czterech modeli GRU: jedno-, dwu-, trzy- i czterowarstwowego.

Podobnie jak w przypadku LSTM, modele z parzystą liczbą warstw wewnętrznych wykazują najniższe straty uczenia. Jednak w przypadku wszystkich modeli GRU straty

wydają się wyższe niż w przypadku LSTM. Porównanie strat dla trzech testowanych modeli pokazano na rys. 27.



Rys. 27. Średni błąd procentowy między wartością przewidywaną a rzeczywistą dla zestawu walidacyjnego modelu SAE i czterowarstwowych modeli GRU i LSTM.

Dane syntetyczne, przeznaczone do testowania wytrenowanych modeli, zostały wytworzone za pomocą programu do mikroskopowej symulacji ruchu drogowego Vissim. Kalibracja programu opisana została w początkowej części niniejszego rozdziału.

W eksperymencie zastosowany został model W-99, do którego, zgodnie z zaleceniami przedstawionymi w literaturze [78], przyjęto następujące wartości parametrów kalibracji:


CC0:	1,5 m
CC1:	0,9 s
CC2:	4 m
CC3:	-8
CC4:	-0,35
CC5:	0,35
CC6:	11,44 1/(m x s)
CC7:	0,25 m/s ²
CC8:	3,5 m/s ²
CC9:	1,5 m/s ²

Założono, że w strumieniu ruchu uczestniczą tylko samochody osobowe (90,1%) i ciężarowe (9,9%), a dozwolone prędkości, zgodnie z przepisami USA, wynoszą odpowiednio 70 mph i 55 mph, czyli 112,6 km/h i 88,5 km/h. Rozkład natężenia ruchu został określony na podstawie danych PeMS od 1 do 7 maja.

Rys. 28÷35 ilustrują wyniki uzyskane z eksperymentów, tj. wyniki predykcji uzyskane za pomocą modeli opisanych powyżej. Wszystkie poniższe wykresy natężenia ruchu zostały znormalizowane, aby ułatwić ocenę wyników.

Rys. 28 przedstawia wyniki przewidywania dla jednowarstwowych modeli LSTM i GRU oraz modelu SAE. Jak wspomniano, model SAE został przetestowany tylko w konfiguracji trójwarstwowej, opisanej powyżej, dlatego dalej używana będzie nazwa „SAE”, bez wymieniania szczegółów jego architektury.

Uzyskany wykres nie ujawnia znaczących różnic pomiędzy modelami, ale można zauważyć, że górne odcinki krzywych nie pokrywają się z linią wyznaczoną przez rzeczywiste dane. Dane liczbowe parametrów zawarte w Tabeli 1 również nie wykazują znaczących różnic, z wyjątkiem mape, który dla modelu SAE jest wyraźnie większy niż dla pozostałych modeli.




Rys. 28. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 1-warstwowe LSTM i GRU dla 5-dniowego przedziału czasowego .

Tabela 1. Metryki błędów predykcji przedstawionej na rys. 28.

	LSTM	GRU	SAE
explained_variance_score	0,981526	0,982227	0,982012
mape	0,079151	0,081650	0,090258
mae	0,029685	0,031415	0,029561
mse	0,001531	0,001633	0,001487
rmse	0,039128	0,040408	0,038562
r2	0,981221	0,979973	0,981761


Rys. 29 przedstawia wyniki przewidywania dla dwuwarstwowych modeli LSTM i GRU oraz modelu SAE. Można zauważyć, że wykres odpowiadający modelowi GRU znajduje się wyraźnie poniżej linii LSTM i SAE. Wartości liczbowe mape przedstawione w tabeli 2 potwierdzają tę obserwację: błąd dla GRU jest bardziej znaczący.



Rys. 29. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 2-warstwowe LSTM i GRU dla 5-dniowego przedziału czasowego.

Tabela 2. Metryki błędów predykcji przedstawionej na rys. 29			
	LSTM	GRU	SAE
explained_variance_score	0,982144	0,978448	0,981211
Mape	0,086983	0,109168	0,079977
Mae	0,029304	0,035923	0,030026
Mse	0,001461	0,002053	0,001532
Rmse	0,038217	0,045307	0,039146
r2	0,982086	0,974822	0,981204


Rys. 30 przedstawia wyniki przewidywania dla SAE oraz trójwarstwowych modeli LSTM i GRU. W tym przypadku nie widać znaczących różnic między przewidywaniami, a wartości liczbowe pokazane w Tabeli 3 są podobne, chociaż wartość mape dla GRU jest największa.



Rys. 30. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 3-warstwowe LSTM i GRU dla 5 - dniowego przedziału czasowego.

Tabela 3. Metryki błędów predykcji przedstawionej na rys. 30.			
	LSTM	GRU	SAE
explained_variance_score	0,982213	0,982460	0,981234
mape	0,084427	0,089500	0,082789
mae	0,031964	0,029042	0,030540
mse	0,001666	0,001433	0,001550
rmse	0,040818	0,037861	0,039366
r2	0,979565	0,982418	0,980993


Rys. 31 przedstawia wyniki przewidywania dla modelu SAE oraz czterowarstwowych modeli LSTM i GRU. Podobnie jak w poprzednich przypadkach, tylko mape wykazuje bardziej znaczące różnice, podczas gdy inne parametry są bardzo podobne. W przypadku GRU mape przyjmuje wartość podobną jak dla modelu dwuwarstwowego, wyraźnie bardziej znaczącą niż pokazana dla LSTM i SAE.




Rys. 31. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 4-warstwowe LSTM i GRU dla 5 - dniowego przedziału czasowego.

Tabela 4. Metryki błędów predykcji przedstawionej na rys. 31.			
	LSTM	GRU	SAE
explained_variance_score	0,979126	0,980331	0,980191
mape	0,094460	0,104544	0,086037
mae	0,032383	0,031820	0,033098
mse	0,001702	0,001642	0,001967
rmse	0,041257	0,040523	0,044350
r2	0,979122	0,979858	0,975875

Rys. 32 i 33 przedstawiają wyniki prognoz modeli trójwarstwowych dla krótszych okresów, odpowiednio 24 godzin i 8 godzin. Z wykresów widać, że prognozy nie nadążają za szybszymi zmianami w rzeczywistych danych. Jest to szczególnie wyraźne w górnej, w przybliżeniu płaskiej części wykresu pokazanego na rys. 32 i poprzednich, tj. na rys. 28-31.




Rys. 32. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 3-warstwowe LSTM i GRU dla 24-godzinnego przedziału czasowego.




Rys. 33. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 3-warstwowe LSTM i GRU dla 8-godzinnego przedziału czasowego.

Wyniki predykcji modeli SAE i czterowarstwowego LSTM i GRU pokazano na rys. 34 i 35. Podobnie jak w przypadku modeli trójwarstwowych, prognozy nie nadążają za szybkimi zmianami danych rzeczywistych.



Rys. 34. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 4-warstwowe LSTM i GRU dla 24-godzinnego przedziału czasowego.



Rys. 35. Rezultat przewidywania natężenia ruchu przez modele SAE oraz 4-warstwowe LSTM i GRU dla 8-godzinnego przedziału czasowego.

Przygotowanie modeli, zwłaszcza LSTM, okazało się stosunkowo czasochłonnym zadaniem. Skrócenie czasu obliczeń okazało się możliwe, gdy do uczenia modeli włączono zasoby obliczeniowe karty graficznej, co skróciło wymagany czas o około 400 razy. Problem ten mógłby stać się znaczący, gdyby wyuczone modele zostały zaimplementowane w urządzeniach o stosunkowo niewielkich zasobach obliczeniowych,

np. w inteligentnych znakach drogowych [8]. Co więcej, oprogramowanie musi być aktualizowane ze względu na zmieniające się warunki drogowe. Z tego punktu widzenia model SAE okazał się najlepszy, tj. najmniej energochłonny, na drugim miejscu uplasował się GRU, a na trzecim LSTM. Wnioski z publikacji [92], dotyczące znacznie niższych kosztów obliczeniowych modelu GRU w porównaniu do LSTM zostały w ten sposób potwierdzone. Podczas gdy potrzeby obliczeniowe mogą być niezbędne dla konkretnych zastosowań, dokładność predykcji jest niewątpliwie ważniejszym kryterium oceny jakości modelu. W tym miejscu należy wspomnieć o dwóch obserwacjach:

1. Na etapie uczenia wyraźna jest zależność strat od rodzaju wewnętrznej architektury modeli, czyli od liczby warstw wewnętrznych. Można zaobserwować, że wraz ze wzrostem liczby warstw rośnie dokładność modeli (GRU i LSTM), choć nie jest to zależność liniowa. Jak wspomniano powyżej, najlepsze wyniki uczenia osiągnęły modele zawierające parzystą liczbę warstw, tj. dwie lub cztery. Wśród nich modele czterowarstwowe wykazywały najniższe błędy uczenia. Efekt ten można zaobserwować na rys. 25 i 26.
2. Jak widać na rys. 27, model SAE okazał się najmniej dokładny spośród testowanych modeli. Z drugiej strony model LSTM wydaje się nieco dokładniejszy niż model GRU o podobnej architekturze.

Wynikowa dokładność predykcji jest wyrażona przez metryki pokazane w tabelach 1÷4, podobnie jak w przypadku procesu uczenia, który zależy od architektury modeli. Jednowarstwowe modele LSTM i GRU dały najlepsze wyniki (tabela 1), co wydaje się być sprzeczne z powyższymi uwagami dotyczącymi procesu uczenia. Z drugiej strony, modele LSTM i GRU z parzystą liczbą warstw wewnętrznych dały znacznie gorsze wyniki, niż trening z rzeczywistymi danymi. W ogólności, modele trójwarstwowe okazały się najdokładniejsze. Wskaźniki pokazane w tabeli 3 są dość wyrównane, ale można zauważyć, że model GRU wypada najmniej korzystnie w tym porównaniu.

Rozdział 4

Opis realizacji elementów systemu

Tematami wcześniejszych rozdziałów były aspekty teoretyczne, związane z modelowaniem ruchu drogowego oraz zastosowaniem uczenia maszynowego w Inteligentnych Systemach Transportowych. Opisano również przeprowadzone eksperymenty, służące weryfikacji sformułowanych w rozprawie tez. Ponieważ niniejsza rozprawa związana jest z programem Doktoratów Wdrożeniowych, rozdział 4, bieżący, poświęcony jest aspektom wdrożeniowym. W dalszej części rozdziału przedstawione zostały najważniejsze, praktyczne wyniki prac rozwojowych, które zostały przeprowadzone w ramach wspomnianego w rozdziale 1.1 projektu INZNAK. Rezultatem tych prac były prototypy głównych składników fizycznych autonomicznego systemu sterowania ruchem drogowym, a zatem:

- prototyp inteligentnego znaku drogowego zmiennej treści
- wybrane czujniki, opracowane w ramach projektu
- podsystem łączności bezprzewodowej
- pozostałe podzespoły zaprojektowane i wykonane przy współudziale autora niniejszej rozprawy

Składniki te zostały krótko przedstawione w dalszej części tego rozdziału.

4.1 Kluczowe elementy systemu

Inteligentny znak drogowy

Podstawową funkcją inteligentnego znaku drogowego (IZD) jest wyznaczenie sugerowanego limitu prędkości ruchu pojazdów w zależności od aktualnego stanu ruchu, stanu nawierzchni, warunków meteorologicznych, widoczności oraz informacji pochodzącej od innych inteligentnych znaków pracujących w ramach tej samej sieci. Dla osiągnięcia tego celu IZD został wyposażony w następujące funkcje:


- pomiar prędkości pojazdów
- zliczanie pojazdów, statystyki ruchu drogowego
- zbieranie danych meteorologicznych
- zbieranie danych o warunkach na drodze (oświetlenie, czystość powietrza, itp.)
- sterowanie wyświetlaczem
- komunikację z innymi IZD

Z punktu widzenia uczestnika ruchu drogowego znak ten może być opisany jako znak zmiennej treści, wyświetlający znak B-33 (ograniczenie prędkości).

Idea pracy pojedynczego inteligentnego znaku zobrazowana jest na rys. 36. Na rysunku wyróżniono obszar monitorowany, zawierający drogę, poruszające się pojazdy i (symbolicznie) warunki pogodowe oraz strukturę inteligentnego znaku, podzieloną na trzy bloki funkcjonalne:

- blok zawierający zestaw czujników o zróżnicowanych modalnościach i wyświetlacz
- blok jednostki zarządzania, zawierający moduły analizujące dane dostarczane przez zestaw czujników i moduł decyzyjny
- blok obsługujący łączność bezprzewodową (na rysunku oznaczony jako Moduł Transmisji).

Symbolicznie zaznaczono także element zewnętrznego nadzoru (Dyspozytor Ruchu), którym w rzeczywistości jest system zarządzania i nadzoru zbudowany w oparciu o technologię chmurową.



Rys. 36. Idea pracy inteligentnego znaku drogowego.

Blok funkcjonalny czujników (oznaczony na rys. 36 jako *Podzespoły*) zawiera następujący zestaw czujników:

- kamerę wizyjną
- stację pogodową
- czujnik opadów
- laserowy czujnik czystości powietrza
- wektorową sondę akustyczną
- mikrofalowy detektor pojazdów
- optyczny detektor pojazdów (Lidar)
- detektor adresów MAC
- czujnik natężenia światła

Poniżej przedstawiony jest krótki opis wybranych czujników:

- **Kamera wizyjna:** przeznaczona jest do zliczania i klasyfikacji typów pojazdów oraz wyznaczania parametrów ruchu za pomocą analizy obrazu. Analiza ruchu drogowego w ciągu dnia opiera się na algorytmach odejmowania tła oraz w oparciu o sieci neuronowe.

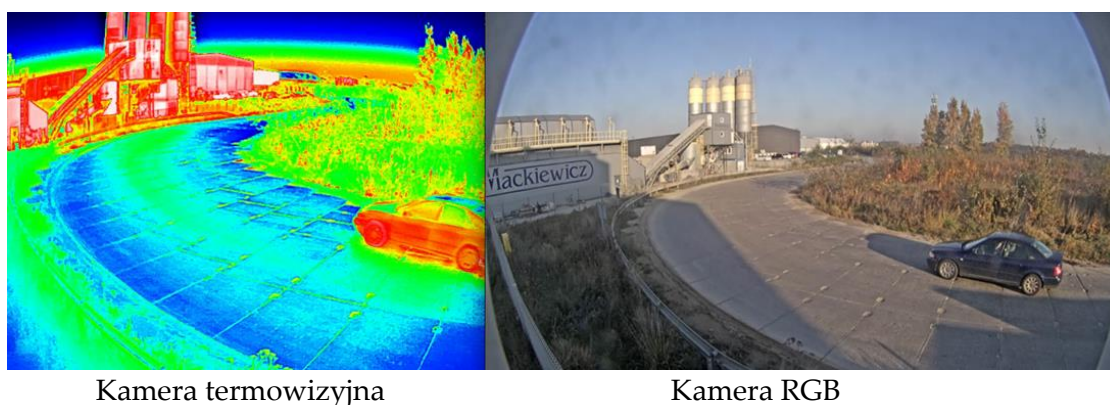
Przeprowadzone eksperymenty wykazały, że sieć neuronowa zapewnia bardziej stabilne i precyzyjne wyniki niż deterministyczne algorytmy odejmowania tła. Uwidocznione jest to na rys. 37.




Rys. 37. Klasyfikacja pojazdów na podstawie nagrania wideo z algorytmem odejmowania tła (rys. (a)) oraz z zastosowaniem sieci neuronowej (rys. (b)).

Detekcja pojazdów w warunkach nocnych możliwa jest za pomocą dwóch metod: śledzenia światła drogowych lub za pomocą kamer termowizyjnych. Obrazy pochodzące z instalacji testowej z kamerą termowizyjną AXIS Q1942-E oraz kamerą RGB AXIS Q1615 Mk II przedstawione są na rys. 38. Zastosowanie kamer termowizyjnych daje lepsze rezultaty, jednak pozyskanie rzeczywistych danych niezbędnych do treningu sieci jest trudne. Jako alternatywne rozwiązanie zastosowano neuronowy transfer stylu, dzięki czemu możliwe było wygenerowanie danych syntetycznych, symulujących dane z kamery

termowizyjnej, na podstawie obrazów z kamery RGB. Wynik takiej transformacji pokazany jest na rys. 39.



Rys. 38. Obraz z kamery termowizyjnej oraz RGB.



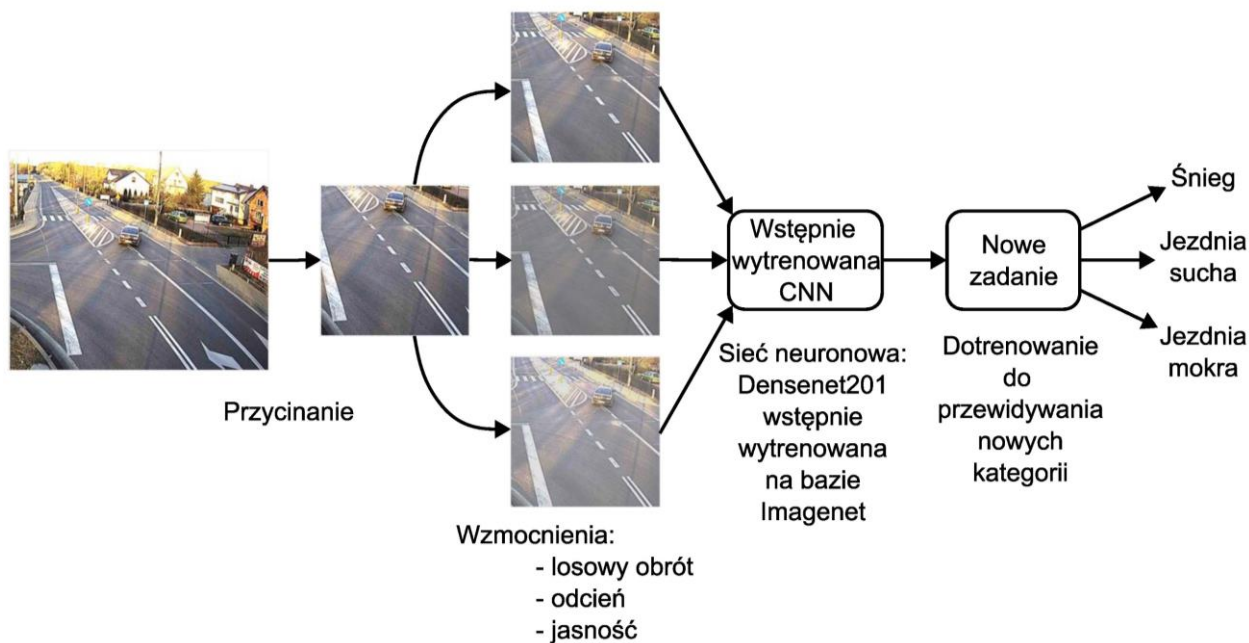
Rys. 39. Przykład neuronowego transferu stylu.

Aplikacja zawierająca moduł zliczający pojazdy na podstawie analizy wielospektralnej reprezentacji obrazów została uruchomiona na komputerze Nvidia Jetson TX2, przy prędkości 9,2 FPS.

Przeprowadzone eksperymenty i badania algorytmów detekcji pojazdów zostały opisane w publikacjach [93]–[95]

Drugim zastosowaniem kamery wizyjnej jest ocena stanu nawierzchni drogi. W tym celu wykonane zostało oprogramowanie, pobierające i archiwizujące z sieci pomiarowych Generalnej Dyrekcji Dróg Krajowych i Autostrad, zdjęcia drogowe wraz z informacją o odpowiadających im warunkach atmosferycznych. Do przetworzenia zebranego zbioru danych wykorzystane zostały splotowe sieci neuronowe. Uzyskane w ten sposób dane

posłużyły do wytrenowania sieci CNN z transferem wiedzy. Metodę ilustruje rys. 40.




Rys. 40. Ilustracja metody oceny stanu nawierzchni jezdni za pomocą analizy obrazu i CNN.

Opisana metoda pozwoliła na osiągnięcie dokładności bliskiej 97%, przewyższającej najnowocześniejsze metody radarowe.

- **Wektorowa sonda akustyczna (WSA):** powstała w wyniku prac prowadzonych w Katedrze Multimedialnej Politechniki Gdańskiej i została objęta ochroną patentową [9], [96], [97].


Rys. 41 przedstawia pogładowy model 3D wektorowej sondy akustycznej, ilustrujący jej działanie.




Rys. 41. Model 3D wektorowej sondy akustycznej.

Sonda natężeniowa jest skonstruowana z sześciu cyfrowych mikrofonów

typu MEMS, generujących strumień danych w formacie I2S. Mikrofony są zamocowane na płytkach drukowanych tworzących sześćian o boku 10 mm (rys. 42). Układ ten podłączony jest przewodowo do układu odbiorczego, który zapewnia odbiór danych w formacie I2S oraz przesłanie danych do komputera poprzez złącze USB (rys. 43). Obudowa czujnika akustycznego wraz z elementami transmisyjnymi przedstawiona jest na rys. 44. Oprogramowanie analizujące sygnały akustyczne realizuje procedury odbioru danych, korekcji poszczególnych sygnałów oraz umożliwia wyznaczenie wartości natężenia dźwięku w trzech wymiarach (X, Y, Z) oraz kątów azymutu i elewacji, wskazujących na kierunek napływającego dźwięku.




Rys. 42. Budowa czujnika akustycznego WSA.



Rys. 43. Uproszczony schemat blokowy wektorowej sondy akustycznej.

Sonda natężeniowa umożliwia zliczanie pojazdów, określenie kierunku ruchu, określenie typu pojazdu (osobowy / ciężarowy) oraz określenie stanu nawierzchni (mokra / sucha) [98].




Rys. 44. Czujnik akustyczny WSA w obudowie.

Dokładność zliczania pojazdów została oszacowana na podstawie eksperymentów terenowych, w których jako urządzenie referencyjne wykorzystany był Metrocount MC5600 Vehicle Counter System [99], oparty na węzłach pneumatycznych. Rezultaty zostały przedstawione w Proceeding of Meetings on Acoustics, vol. 42, 179th Meeting of the Acoustical Society of America [100].


Autor niniejszej rozprawy miał możliwość uczestniczenia w pracach nad WSA, wykonując m.in. dwie zmodyfikowane wersje czujnika akustycznego sondy wraz z elementami interfejsu transmisyjnego oraz obudowy (rys. 42 i 44). Więcej szczegółowych informacji znajduje się w publikacjach [100]–[105].

- **Mikrofalowy detektor pojazdów (MDP):** został skonstruowany w oparciu o mikrofalowy czujnik radarowy RSM2650 firmy B+B Sensors, pracujący w paśmie 24 - 24.250GHz. Czujnik ten przedstawiony jest na rys. 45. Dzięki niestandardowej konstrukcji oraz wprowadzonym ulepszeniom urządzenie to charakteryzuje się bardzo dobrymi parametrami użytkowymi i bardzo niską ceną. Jest ono obecnie objęte ochroną patentową [106]. MDP umożliwia akwizycję i analizę sygnału w czasie rzeczywistym, wstępną obróbkę sygnału polegającą na słumieniu zakłóceń, wybór kierunku jazdy na drogach dwukierunkowych, wykrywanie i śledzenie pojazdów oraz pomiar prędkości.




Rys. 45. Mikrofalowy czujnik radarowy RSM2650.

Opracowany algorytm detekcji oparty jest na ocenie różnicy pomiędzy widmami fazowymi sygnałów rejestrowanych z dwóch kanałów wyjściowych I/Q czujnika, obliczonych za pomocą szybkiej transformaty Fouriera. Przykładowy spektrogram uzyskany z instalacji testowej przedstawiony jest na rys. 46.




Rys. 46. Spektrogram sygnału zarejestrowanego z czujnika dopplerowskiego (przejazdy samochodów). Oś pozioma: indeks ramki analizy, oś pionowa: prędkość w km/h.

Rezultat działania algorytmu zmniejszającego zakłócenia oraz analizującego i przypisującego prędkości wykrytym pojazdom przedstawia rys. 47.



Rys. 47. Wyniki analizy danych z rys. 46. Oś pozioma: indeks ramki analizy, oś pionowa: prędkość w km/h.


Podobnie jak w przypadku opisanej wyżej WSA, dokładność zliczania pojazdów została sprawdzona w ramach testów przeprowadzonych za pomocą rejestratora wchodzącego w skład zestawu eksperymentalnego, zainstalowanego przy ulicy Traugutta w Gdańsku. Jako czujnik referencyjny zastosowane zostało urządzenie Metrocount MC5600 Vehicle Counter System. Rezultat pomiarów przedstawiony jest na rys. 48.



Rys. 48. Liczba pojazdów na godzinę i średnia prędkość pojazdów na godzinę, dla czujnika dopplerowskiego (kolor niebieski) i dla Metrocount (kolor pomarańczowy).

Uzyskane wyniki estymacji prędkości wykazują pewną rozbieżność wartości, jednak zgodność tendencji jest bardzo dobra. Rezultaty oceny dokładności oraz porównanie z WSA zostały przedstawione w *Proceeding of Meetings on Acoustics*, vol. 42, 179th Meeting of the Acoustical Society of America [100]. Więcej informacji dostępnych jest w publikacji [107].

Wyświetlacz jest ostatnim elementem występującym na rys. 36 w bloku podzespołów. Ma on budowę modułową, umożliwiającą skalowanie powierzchni z dokładnością do panelu (rys. 49) o wymiarach 201 mm x 201 mm.



Rys. 49. Panel wyświetlacza IZD, rozdzielczość 8 x 8 pikseli RGB.

Piksele w panelu zorganizowane są w cztery grupy 4 x 4 piksele, z których każda wyposażona jest w kontroler umożliwiający sterowanie świeceniem poszczególnych pikseli oraz komunikację z nadrzędną jednostką w technologii RS-485. Elementy konstrukcji pokazane są na rys. 50.



Hub RS-485



Moduł zasilający i komunikacyjny RS-485



Okablowanie

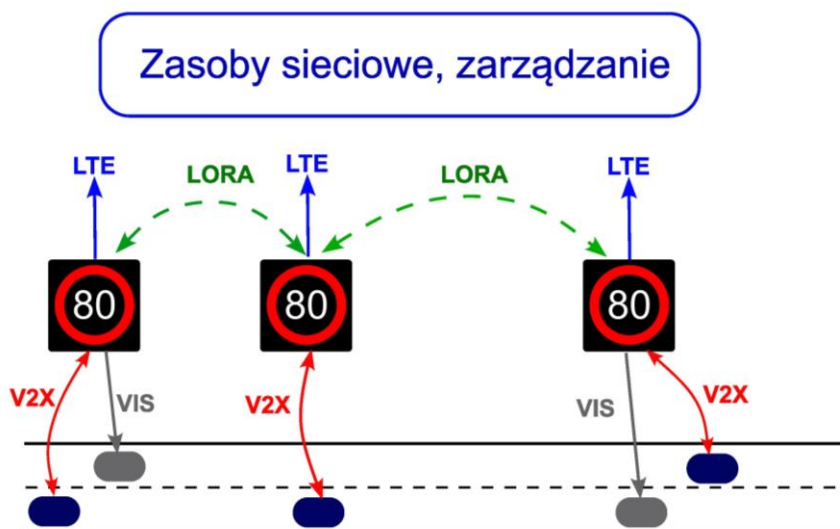
Rys. 50. Elementy łączące panele wyświetlacza.

Wykonane zostały dwa projekty IZD różniące się wymiarami wyświetlacza: 4 x 4 panele oraz 4 x 6 paneli (rys. 68). Zaprojektowany system sterowania umożliwia wyświetlanie obrazów statycznych oraz zmiennych z prędkością do 60 FPS.

Blok funkcjonalny jednostki zarządzania zawiera mikrokomputer sterujący pracą IZD. W opisanym dalej modelu badawczym jako główną jednostkę sterującą zastosowano Kontron pITX-E38, do obsługi czujników środowiskowych zastosowano mikrokomputer Raspberry Pi-4, natomiast do analiz prowadzonych z użyciem sieci neuronowych wykorzystano mikrokomputer Nvidia Jetson TX2i. Jest to konfiguracja nadmiarowa, jednak należy zauważyć, że służyła ona celom badawczym. Wdrożenie do produkcji będzie wymagało optymalizacji wymienionych zasobów.

Podsystem łączności

Podsystem łączności zapewnia komunikację w trzech obszarach: pomiędzy systemem nadzoru / zarządzania i poszczególnymi znakami lub grupami znaków, pomiędzy znakami oraz pomiędzy znakami i uczestnikami ruchu. Symbolicznie przedstawiono tę strukturę na rys. 51. W przypadku pojazdów, które nie są wyposażone w interfejs V2X, komunikacja odbywa tradycyjnie, czyli poprzez wyświetlanie odpowiedniej treści na wyświetlaczu znaku, co oznaczono na rysunku symbolem VIS.



Rys. 51. Schemat blokowy system łączności.

Rozproszona i skalowalna budowa systemu inteligentnych znaków zawiera trzy poziomy wymiany informacji w systemie:

- Wymiana danych Centrum Zarządzania INZNAK – grupa znaków
- Wymiana danych znak – znak
- Wymiana danych V2X

Grupa Inteligentnych Znaków rozmieszczona wzdłuż monitorowanej drogi tworzy system urządzeń. W ramach tego systemu, znaki wymieniają informacje dotyczące danych z czujników oraz podejmowanych decyzji. Przyjęto założenie, że każdy znak w ramach systemu ma dostęp do wszystkich danych wysyłanych przez pozostałe znaki. Systemy znaków komunikują się z serwerem systemu zarządzania.

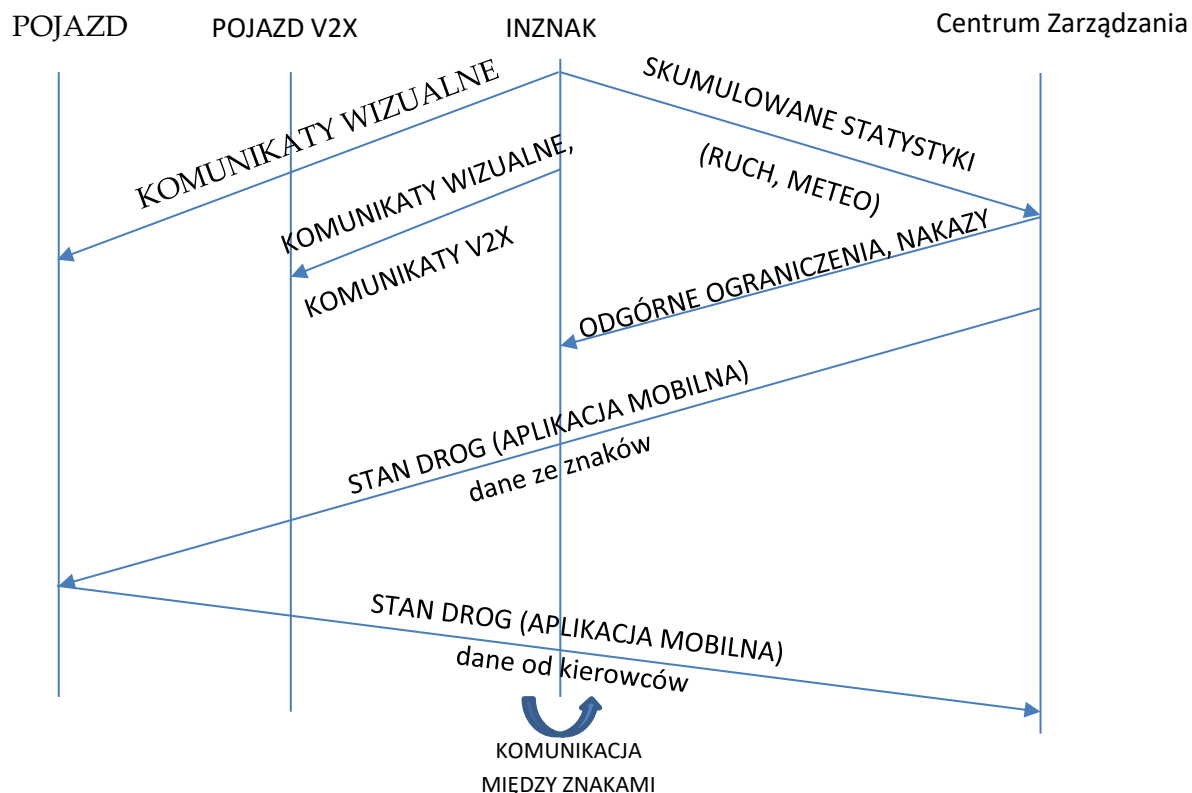
Możliwe są dwie metody realizacji systemu komunikacji pomiędzy znakami:

- System autonomiczny – w tej koncepcji znaki tworzą niezależny system komunikacyjny i korzystają z sieci transmisyjnej zbudowanej na potrzeby projektu. Komunikacja odbywa się metodą peer-to-peer. System łączy się z zewnętrzną siecią (serwerem) w jednym punkcie (bramie), która izoluje system znaków od sieci zewnętrznej i przekazuje jedynie potrzebne komunikaty.
- System scentralizowany –budowanie specjalnej sieci nie jest wymagane. Komunikacja między znakami odbywa się za pośrednictwem serwera. Łączność jest zapewniana przez zewnętrznego operatora sieci, np. LTE.

W systemie autonomicznym przewidziane jest wykorzystanie bezprzewodowej technologii LPWAN (Low-Power Wide-Area Network). Pierwsza warstwa modelu OSI (warstwa fizyczna) jest realizowana przy pomocy technologii LoRa, druga warstwa (warstwa łącza danych) jest opisana jako standard LoRaWAN [108]. Jest to standard bezprzewodowej łączności urządzeń w paśmie częstotliwości 868 MHz (w Europie). Transmisja danych odbywa się za pomocą modulacji CSS (Chip Spread Spectrum). Technologia LPWAN jest wykorzystywana m.in. do transmisji danych w systemach Internetu rzeczy (IoT). Cechuje się dużym zasięgiem transmisji, w terenie otwartym podaje się typowy zasięg 22 km, w terenie miejskim jest to ok. 2 km. Prędkość transmisji mieści się w zakresie od 250 bps do 5,5 kbps. Zaletą tej technologii jest bardzo niski pobór energii.

Komunikacja z pojazdami wyposażonymi w stosowne urządzenia odbywa się w technologii V2X. Jest to rozwiązanie przyszłościowe, z tego względu w konstrukcji modelu badawczego IZD zaimplementowano urządzenie RSU-101E (*Roadside Unit*) firmy UNEX. Testy komunikacji przeprowadzono z użyciem urządzenia OBU-201E (*On-Board-Unit*). W tym celu wykonane zostało oprogramowanie dla RSU i OBU, pozwalające na przesyłanie komunikatów V2X pomiędzy podłączonymi do nich urządzeniami. Przeprowadzone testy udowodniły poprawne działanie wykonanego oprogramowania. W toku dalszych prac zostaną również przeprowadzone eksperymenty w terenie, mające na celu zbadanie poprawności działania systemu przy dużych prędkościach pojazdu i przy większej odległości od RSU.


Struktura komunikacji systemowej przedstawiona jest na rys. 52. Na rysunku pokazano kierunki przepływu poszczególnych typów informacji pomiędzy centrum zarządzania, inteligentnymi znakami oraz uczestnikami ruchu drogowego.



Rys. 52. Struktura komunikacji systemowej.

Jak już wyżej stwierdzono, architektura systemu pozwala również na pracę autonomiczną. Sieć łączności bezprzewodowej w technologii Lora pozwala na wymianę informacji pomiędzy znakami i wypracowywanie decyzji na podstawie danych pochodzących od każdego z nich. Z kolei, zaimplementowane w każdym znaku mechanizmy głębokiego uczenia maszynowego, pozwalają na przeprowadzanie w czasie rzeczywistym analizy danych dostarczanych przez zespoły czujników.

inteligentnego znaku, zainstalowany na terenie Katedry Multimedialnej, oraz urządzenie badawcze zamontowane na ścianie budynku firmy Technoservice. Wnętrze urządzenia badawczego, zawierającego większość czujników, przedstawione jest na rys. 54, natomiast miejsce i sposób montażu na rys. 55 i 56.



Rys. 54. Wnętrze szafy pomiarowej z zamontowanymi podzespołami.



Rys. 55. Szafa pomiarowa z czujnikami zewnętrznymi, widoczny sposób doprowadzenia zasilania.



Rys. 56. Miejsce instalacji szafy badaniowej - widok od strony jezdni, ul. Traugutta.

Lokalizacja przy ul. Traugutta okazała się przydatna, ale umożliwiła badania jedynie w warunkach miejskich. Z uwagi na potrzebę prowadzenia badań drogowych przy drogach z dopuszczalnymi prędkościami powyżej 50 km/h, wykonana została instalacja przy Alei Lipowej w Leźnie. Rys. 57 przedstawia lokalizację punktu pomiarowego, natomiast proces instalowania urządzeń pokazano na rys. 58.




Rys. 57. Położenie punktu pomiarowego. Odległość punktu od drogi S7 585 m.



Rys. 58. Proces instalowania urządzenia pomiarowego. U dołu szafka zasilająca.
Lokalizacja Leźno, Aleja Lipowa

Wnętrze urządzenia pomiarowego przedstawione jest na rys. 59.



Rys. 59. Wnętrze urządzenia pomiarowego. Lokalizacja Leźno, Aleja Lipowa.

Punkt pomiarowy funkcjonował przez cztery miesiące. Przez ten okres rejestrowano dane pogodowe, dane z czujnika radarowego i lidarowego, dane wizyjne (kamera) oraz audio (sonda, mikrofon zewnętrzny, mikrofon wewnętrzny). Wyniki badań prowadzonych przy ul. Traugutta w Gdańsku i Alei Lipowej w Leźnie pozwoliły na stwierdzenie, że opracowany model inteligentnego znaku jest w stanie działać w sposób ciągły i bezawaryjny przez dłuższy czas, przekazując z użyciem LTE zbierane dane do serwera, bądź zapisując je na wbudowanych dyskach.


Po zakończeniu pomiarów w Leźnie, urządzenie pomiarowe zostało przeniesione do nowej lokalizacji, położonej na drodze ekspresowej S7 (okolice miejscowości Dworek, woj. Pomorskie). W efekcie prowadzonych z GDDKiA rozmów uzyskano zgodę na montaż szafki pomiarowej przy bramownicy znajdującej się na 30. kilometrze drogi S7, na jezdni w stronę Gdańska (.



Rys. 60. Moduł pomiarowy w trakcie montażu przy drodze S7

Na podstawie przeprowadzonych badań w różnych lokalizacjach potwierdzono, że przyjęta koncepcja konstrukcji elementów sensorów, akwizycji, przetwarzania i składowania dla inteligentnego znaku jest odpowiednia do działania w sposób ciągły przez dłuższy czas. Jednocześnie sprawdzono, że wybrany zestaw czujników może być z powodzeniem wykorzystany przy typowej drodze ekspresowej.

Ze względu na brak możliwości podłączenia zasilania z sieci energetycznej zastosowano zasilanie za pomocą akumulatorów, które zapewniały stabilną pracę całego zestawu urządzeń. Na rys. 61 przedstawiono dane statystyczne uzyskane za okres obserwacji w instalacji w Leźnie, wygenerowane przez system Grafana na podstawie wyników detekcji pojazdów i pomiaru ich prędkości (z użyciem czujnika radarowego i algorytmów opracowanych w trakcie realizacji projektu), zapisanych w bazie danych.



Rys. 61. Dane statystyczne uzyskane w instalacji w Leźnie na podstawie detekcji pojazdów i pomiaru ich prędkości z użyciem czujnika radarowego, wygenerowane przez system Grafana.

Druga stacjonarna instalacja testowa została wykonana na terenie firmy TSTRONIC, przy ul. Benzynowej w Gdańsku. Instalacja zawiera pojedynczy egzemplarz znaku oraz adaptacyjny układ zasilania solarno-wiatrowego, przedstawiony na rys. 62.

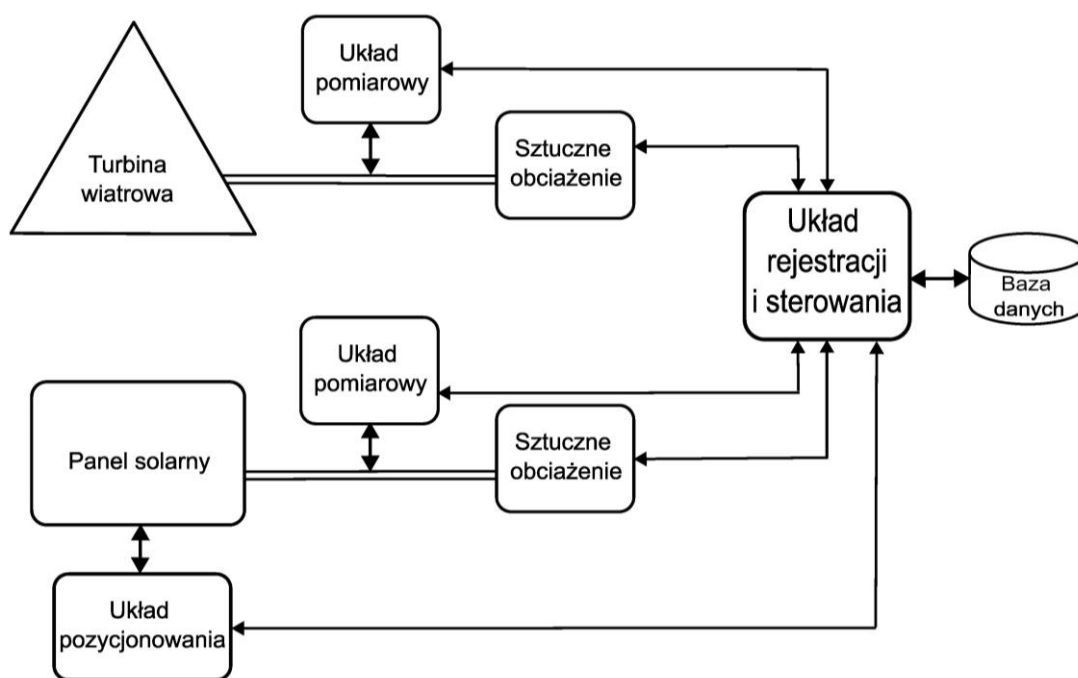
Układ automatycznego pozycjonowania panelu solarnego zrealizowany jest za pomocą dwóch siłowników elektrycznych, sterowanych przez porty GPIO mikrokomputera sterującego. Do obliczania pozycji wykorzystany został algorytm opisany w artykule „Low-precision formulae for planetary positions”, Van Flandern, T. C.; Pulkkinen, K. F., *Astrophysical Journal Supplement Series*, Vol. 41, Nov. 1979, P. 391-411.





Rys. 62. Prototypowa instalacja systemu zasilania inteligentnego znaku.

Schemat blokowy układu pomiarowego zastosowanego do testowania wydajności energetycznej turbiny wiatrowej oraz panelu solarnego przedstawiony jest na rys. 63.




Rys. 63. Schemat blokowy układu pomiarowego do testowania wydajności energetycznej turbiny wiatrowej oraz panelu solarnego.

Rejestrowane są następujące parametry:


- Czas pomiaru
- Temperatura systemu
- Temperatura obciążenia 1
- Temperatura obciążenia 2

- Napięcie z turbiny wiatrowej
- Prąd z turbiny wiatrowej
- Moc z turbiny wiatrowej
- Prędkość obrotowa turbiny wiatrowej
- Napięcie z panelu słonecznego
- Prąd z panelu słonecznego
- Moc z panelu słonecznego


Dane rejestrowane były od czerwca do grudnia, natomiast do analizy użyto danych z okresu jesiennie-zimowego, od września do grudnia. Okres ten obejmuje ponad 9 mln rekordów. Otrzymane w ten sposób profile dzienne przedstawione są na rys. 64÷66.



Rys. 64. Profil dzienny energii słonecznej [Wh].



Rys. 65. Profil dzienny energii wiatrowej [Wh].



Rys. 66. Profil dzienny energii łącznej [Wh].

Odpowiednio usytuowana turbina wiatrowa może wytworzyć rocznie taką ilość energii elektrycznej, jaka odpowiada 25% iloczynowi jej mocy nominalnej oraz liczby godzin w ciągu roku (24 h×365 dni). W tak wyliczonej wielkości uwzględnione są zarówno okresy bezwietrzne, jak i te, kiedy prędkość wiatru jest mniejsza lub większa od tej, przy której elektrownia wiatrowa produkuje moc nominalną. Przeprowadzone pomiary i wyniki ich analiz potwierdziły powyższą zasadę i dowodzą zasadności budowania źródeł energii opartych na współdziałaniu kierowanego panelu fotowoltaicznego z turbiną wiatrową.


Trzecia stacjonarna instalacja testowa została wykonana na terenie firmy Microsystem, przy ul. Nowy Świat w Gdańsku. Wykonanie instalacji poprzedzone było pomiarami terenowymi, z wykorzystaniem modalności radarowej, wizyjnej i akustycznej wykonanymi przez zespół Politechniki Gdańskiej. Pomiary wykonano korzystając z radaru TMS-SA zamontowanego na wysokości 2,7 m, dwóch kamer (GoPro + Lamax) zamontowanych na wysokości 2,4m (1920x1080, 120 fps) oraz dwóch mikrofonów kierunkowych (shotgun stereo + kardioda) zamontowanych na osobnych statywach. Przeprowadzono rejestrację danych przez 45 minut. Rys. 67 ilustruje położenie stanowiska badaniowego względem ulicy Nowy Świat. Pomiary te wykorzystane zostały do potwierdzenia przydatności lokalizacji do planowanych badań i sprecyzowania miejsca instalacji stałej, zawierającej kamerę termowizyjną AXIS Q1942-E o rozdzielczości 640x480 pikseli oraz kamerę RGB AXIS Q1615 Mk II o rozdzielczości 1280x720 pikseli. Obrazy z obu kamer przedstawia rys. 38. Dane z obu kamer rejestrowane są w trybie ciągłym na dedykowanym serwerze i udostępniane poprzez kanał VPN. Dane te wykorzystane były m.in. do badań nad wizyjną detekcją i zliczaniem pojazdów oraz do generowania danych syntetycznych.



Rys. 67. Pomiary terenowe w siedzibie firmy Microsystem, ul. Nowy Świat, Gdańsk.

Fizyczna realizacja obu wersji znaku przedstawiona jest na rys. 68. Zaprojektowane i wykonane zostały dwie wersje znaku: mniejsza, umożliwiająca wyświetlanie wyłącznie symboli drogowych (np. ograniczenia prędkości), oraz większa, umożliwiająca dodatkowo wyświetlanie krótkiego komunikatu tekstowego. Jak już wspomniano, wyświetlacz znaku ma budowę modułową, w związku z czym jego wielkość może być w szerokich granicach dostosowywana do potrzeb.

Wszystkie opisane w rozdziale czwartym elementy systemu zostały zaimplementowane w pokazanych na rys. 68 urządzeniach. Dolna część obu znaków przedstawionych na rysunku została odkryta w celach demonstracyjnych. Jest to przestrzeń, w której montowane są te czujniki, które wymagają bezpośredniego dostępu do widoku drogi, np. czujnik radarowy i Lidar. Zaplanowany został standardowy sposób montażu czujników oraz innych niezbędnych elementów, np. przetwornic zasilających, wykorzystujący szynę DIN 35 mm. Wektorowa sonda akustyczna, kamera, czujnik opadów, stacja pogodowa oraz czujnik światła zamontowane są na obudowie znaku (rys. 68 (b)).



Rys. 68. Zrealizowane wersje inteligentnego znaku drogowego.

Treść wyświetlana na znaku (a) służyła jedynie przetestowaniu wyświetlacza i nie jest przewidywana w rzeczywistym zastosowaniu.

Obudowa znaku została wykonana z blachy aluminiowej, dzięki czemu osiągnięto znaczną redukcję ciężaru urządzenia. Powierzchnia czołowa wyświetlacza chroniona jest za pomocą arkusza o grubości 3 mm, wykonanego z poliwęglanu. Zaprojektowany został również poprawiający ergonomię sposób montażu znaku na słupie. Wybrane szczegóły konstrukcji przedstawione są w dodatkach do niniejszej rozprawy.

Prototypy IZD zostały wyposażone w mechanizmy analizy informacji napływającej z obszernego zestawu czujników, mechanizmy decyzyjne oparte na sieciach neuronowych oraz system komunikacji pomiędzy znakami. Elementem wyróżniającym jest grupowy sposób pracy, polegający na wymianie danych i wspólnym, opartym na obserwacjach wszystkich znaków, podejmowaniu decyzji o treści wyświetlanej na poszczególnych wyświetlaczach systemu. Proces ten jest w pełni autonomiczny i nie wymaga bezpośredniej zewnętrznej ingerencji do poprawnego działania. Zewnętrzny system nadzoru jest elementem każdego działającego współcześnie systemu, jednak w przypadku systemu, któremu poświęcona jest niniejsza rozprawa, zewnętrzny nadzór ma raczej charakter uwzględnienia wymogów bezpieczeństwa na wypadek awarii, niż konieczności wynikającej ze sposobu funkcjonowania.

Rozdział 5

Podsumowanie i wnioski

W rozdziale trzecim opisane zostały dwa eksperymenty związane z analizą ruchu drogowego za pomocą symulatora Vissim oraz ich rezultaty. W trzecim eksperymencie, również opisanym w tym rozdziale, symulator Vissim został wykorzystany do wygenerowania danych syntetycznych, służących do testowania modeli ruchu zbudowanych w oparciu o głębokie sieci neuronowe.

Pierwszy eksperyment, którego opis oraz rezultaty zostały przedstawione w czasopiśmie Remote Sensing ([82]), dotyczył sprawdzenia wpływu sposobu stopniowania ograniczenia prędkości na czas przejazdu testowego odcinka drogi. W tym celu zaprojektowany został w środowisku programu Vissim model drogi zbudowany z pięciu dwupasmowych jezdni. Na czterech z nich ustanowiono różnie stopniowane ograniczenia prędkości, jezdnia piąta służyła jako referencyjna, tzn. nie zawierała ograniczeń prędkości innych, niż wynikające z klasy drogi. Na tak zaprojektowanym modelu wykonano serie symulacji bazujące na czterech scenariuszach odpowiadających czterem klasom dróg. Otrzymane rezultaty wykazały, że stopniowanie ograniczenia prędkości powoduje skrócenie czasu przejazdu przez odcinek testowy. Tendencja ta jest niezależna od kategorii drogi, chociaż można również zauważyć, że zwiększone natężenie ruchu wiąże się z zakłóceniami jego płynności. Zwiększenie odległości między znakami spowodowało zauważalne wydłużenie czasu przejazdu. Na podstawie rezultatów tego eksperymentu udowodniona została następująca teza, której przydatność pozwala na ustalenie zasad doboru prędkości na komunikujących się wzajemnie znakach drogowych zmiennej treści:

Teza 1

Za pomocą odpowiedniego doboru stopniowania prędkości możliwe jest zmniejszenie czasu przejazdu odcinka drogi, na którym ustawiono znaki zmiennej treści wyświetlające ograniczenia prędkości.

Drugi eksperyment dotyczył sprawdzenia wpływu odległości pomiędzy znakami zmiennej treści na wariancję prędkości pojazdów. W tym celu w środowisku Vissim zamodelowano fragment Drogi Kaszubskiej, znajdujący się w pobliżu szczytu Wieżyca w województwie pomorskim. Ograniczenia prędkości zostały ustanowione przed i za miejscem, w którym droga zmienia kierunek o 180 stopni. Pomiary ruchu wykonywane były w kilku punktach na opisanym zakręcie, według trzech scenariuszy odpowiadających różnym odległościom pomiędzy punktem początkowym zakrętu i poprzedzającym go znakiem ograniczenia prędkości oraz dla dwóch stanów nawierzchni. Przeprowadzone eksperymenty wykazały, że lokalizacja znaków drogowych ma wyraźny wpływ na wariancję prędkości pojazdów. Uzyskane rezultaty

zostały przedstawione w czasopiśmie IEEE Access ([91]). Wykazały one zasadność następującej tezy pracy, którą można wykorzystać jako przesłankę do ustalania odległości pomiędzy skomunikowanymi znakami zmiennej treści:

Teza 2

Za pomocą doboru odległości pomiędzy znakami ograniczenia prędkości oraz stopnia redukcji prędkości zalecanej możliwe jest zmniejszenie wariacji prędkości pojazdów.

Celem trzeciego eksperymentu było sprawdzenie możliwości testowania modeli rekurencyjnych sieci neuronowych z użyciem danych syntetycznych (inferencja). Do jego przeprowadzenia wykorzystano trzy modele uczenia maszynowego: LSTM, GRU oraz SAE. Jako dane rzeczywiste do trenowania modeli zostały wykorzystane dane udostępnione przez Kalifornijski Departament Transportu (CalTrans) na stronie internetowej Caltrans Performance Measurement System (PeMS). Dane syntetyczne zostały wygenerowane za pomocą programu Vissim. Przeprowadzono testy czterech struktur modeli LSTM i GRU oraz struktury trójwarstwowej modelu SAE, a ich rezultaty zostały przedstawione w artykule przygotowanym do opublikowania. Otrzymane wartości metryk błędów potwierdzają zasadność tezy, która tworzy kolejną regułę użyteczną w procesie projektowania sieci inteligentnych znaków drogowych o następującej treści:

Teza 3

W celu walidacji modeli sterowania ruchem wytrenowanych za pomocą danych rzeczywistych, wystarczające jest ich testowanie za użyciem danych syntetycznych.

Dalsze badania w tej dziedzinie mogą rozwijać się w stronę wykorzystania coraz bardziej zaawansowanych algorytmów opartych na uczeniu maszynowym do optymalizacji zarządzania ruchem drogowym. Rozwój tych badań nie tylko może poprawić efektywność przepływu pojazdów, ale również znacząco zwiększyć bezpieczeństwo na drogach.

Bibliografia

- [1] 'Annual Statistical Report 2022', European Road Safety Observatory, 2022. [Online]. Available: https://road-safety.transport.ec.europa.eu/document/download/287aa31e-48c2-4e04-a9cc-e2ca24d29cc2_en?filename=ERSO_annual_report_20220509.pdf
- [2] European Parliament, 'European Parliament resolution of 13 March 2018 on a European strategy on Cooperative Intelligent Transport Systems'. European Parliament, Mar. 13, 2018. [Online]. Available: https://www.europarl.europa.eu/doceo/document/TA-8-2018-0063_EN.html
- [3] German Federal Statistical Office, 'Driver-related causes of accidents involving personal injury in road traffic', German Federal Statistical Office. Accessed: Jun. 16, 2023. [Online]. Available: https://www.destatis.de/EN/Themes/Society-Environment/Traffic-Accidents/_node.html
- [4] W. Sigloch, 'High Risk of Accidents Caused by People's Behavior'. DEKRA e.V, Aug. 13, 2021. [Online]. Available: <https://media.dekra.com/media/2021-08-13-dekra-press-release-road-safety-report-car-drivers-errors.pdf>
- [5] ACEA, 'Average age of the EU vehicle fleet, by country', European Automobile Manufacturers' Association. [Online]. Available: <https://www.acea.auto/figure/average-age-of-eu-vehicle-fleet-by-country/>
- [6] 'Connected, Cooperative and Automated Mobility Roadmap', ERTRAC. [Online]. Available: <https://www.ertrac.org/wp-content/uploads/2022/07/ERTRAC-CCAM-Roadmap-V10.pdf>
- [7] European Commission. Directorate General for Mobility and Transport., VTT., and ECORYS., *Study on the feasibility, costs and benefits of retrofitting advanced driver assistance to improve road safety: final report*. LU: Publications Office, 2020. Accessed: Aug. 03, 2023. [Online]. Available: <https://data.europa.eu/doi/10.2832/316686>
- [8] A. Czyzewski, A. Sroczynski, T. Smialkowski, and P. Hoffmann, 'Development of Intelligent Road Signs with V2X Interface for Adaptive Traffic Controlling', in *2019 6th International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS)*, Cracow, Poland: IEEE, Jun. 2019, pp. 1–7. doi: 10.1109/MTITS.2019.8883369.
- [9] A. Czyzewski, J. Kotus, and G. Szwoch, 'Sonda natężeniowa wraz z układem korekcji, patent nr 236718', 236718, Feb. 17, 2021
- [10] D. Grabowski and A. Czyzewski, 'System for monitoring road slippery based on CCTV cameras and convolutional neural networks', *J. Intell. Inf. Syst.*, vol. 55, no. 3, pp. 521–534, Dec. 2020, doi: 10.1007/s10844-020-00618-5.

- [11] N. J. Garber and R. Gadiraju, 'Factors affecting speed variance and its influence on accidents'. *Transportation research record*, 1989; 1213: 64-71, 1989. [Online]. Available: <https://onlinepubs.trb.org/Onlinepubs/trr/1989/1213/1213-009.pdf>
- [12] 'The effects of automated speed enforcement systems on traffic-flow characteristics and accidents in Korea'. *ITE journal*, vol. 29, 2003. [Online]. Available: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=b77299742c711d5135315b45ff085a4c6c7c7c1b>
- [13] L. Aarts and I. Van Schagen, 'Driving speed and the risk of road crashes: A review', *Accid. Anal. Prev.*, vol. 38, no. 2, pp. 215-224, Mar. 2006, doi: 10.1016/j.aap.2005.07.004.
- [14] R. Elvik, P. Christensen, and A. H. Amundsen, *Speed and road accidents: an evaluation of the Power Model*. Transportøkonomisk Institutt, 2004. [Online]. Available: https://vbn.aau.dk/ws/files/316398068/Speed_and_road_accidents_PhD.pdf
- [15] 'Manual PTV Vissim'. PTV Planung Transport Verkehr GmbH, 2022.
- [16] S. Krauß, 'Microscopic Modeling of Traffic Flow: Investigation of Collision Free Vehicle Dynamics'. Deutsches Zentrum für Luft- und Raumfahrt, Apr. 06, 1998. [Online]. Available: <https://sumo.dlr.de/pdf/KraussDiss.pdf>
- [17] K. Bevrani, E. Chung, and M. Miska, 'Evaluation of the GHR car following model for traffic safety studies', in *Proceedings of the 25th Australian Road Research Board Conference*, L. Chong, Ed., Australia: Australian Road Research Board (ARRB), 2012, pp. 1-11. Accessed: Aug. 06, 2023. [Online]. Available: <http://www.arrb.com.au/ARRB-Conferences/Conference.aspx?id=3>
- [18] M. Brackstone and M. McDonald, 'Car-following: a historical review', *Transp. Res. Part F Traffic Psychol. Behav.*, vol. 2, no. 4, pp. 181-196, Dec. 1999, doi: 10.1016/S1369-8478(00)00005-X.
- [19] P. G. Gipps, 'A behavioural car-following model for computer simulation', *Transp. Res. Part B Methodol.*, vol. 15, no. 2, pp. 105-111.
- [20] S. Krauss, P. Wagner, and C. Gawron, 'Continuous limit of the Nagel-Schreckenberg model', *Phys. Rev. E*, vol. 54, no. 4, pp. 3707-3712, Oct. 1996, doi: 10.1103/PhysRevE.54.3707.
- [21] K. Nagel and M. Schreckenberg, 'A cellular automaton model for freeway traffic', *J. Phys. I*, vol. 2, no. 12, pp. 2221-2229, Dec. 1992, doi: 10.1051/jp1:1992277.
- [22] A. Schadschneider, 'The Nagel-Schreckenberg model revisited', *Eur. Phys. J. B*, vol. 10, no. 3, pp. 573-582, Aug. 1999, doi: 10.1007/s100510050888.
- [23] M. Treiber, A. Hennecke, and D. Helbing, 'Congested traffic states in empirical observations and microscopic simulations', *Phys. Rev. E*, vol. 62, no. 2, pp. 1805-

1824, Aug. 2000, doi: 10.1103/PhysRevE.62.1805.

- [24] H. U. Ahmed, Y. Huang, and P. Lu, 'A Review of Car-Following Models and Modeling Tools for Human and Autonomous-Ready Driving Behaviors in Micro-Simulation', *Smart Cities*, vol. 4, no. 1, pp. 314–335, Mar. 2021, doi: 10.3390/smartcities4010019.
- [25] M. Bando, K. Hasebe, A. Nakayama, A. Shibata, and Y. Sugiyama, 'Dynamical model of traffic congestion and numerical simulation', *Phys. Rev. E*, vol. 51, no. 2, pp. 1035–1042, Feb. 1995, doi: 10.1103/PhysRevE.51.1035.
- [26] F. Storani, R. Di Pace, F. Bruno, and C. Fiori, 'Analysis and comparison of traffic flow models: a new hybrid traffic flow model vs benchmark models', *Eur. Transp. Res. Rev.*, vol. 13, no. 1, p. 58, Dec. 2021, doi: 10.1186/s12544-021-00515-0.
- [27] R. Wiedemann, 'Simulation des Strassenverkehrsflusses'. Institut für Verkehrswesen der Universität Karlsruhe, 1974.
- [28] R. Wiedemann and U. Reiter, 'Microscopic Traffic Simulation: The Simulation System MISSION, Background and Actual State', Commission of the European Communities, Brussels, Belgium, Project ICARUS (V1052) Final Report, 1992.
- [29] A. Anil Chaudhari, K. K. Srinivasan, B. Rama Chilukuri, M. Treiber, and O. Okhrin, 'Calibrating Wiedemann-99 Model Parameters to Trajectory Data of Mixed Vehicular Traffic', *Transp. Res. Rec. J. Transp. Res. Board*, vol. 2676, no. 1, pp. 718–735, Jan. 2022, doi: 10.1177/03611981211037543.
- [30] H. Rakha and Y. Gao, 'Calibration of steady-state car-following models using macroscopic loop detector data', Virginia Transportation Research Council, VT-2008-01, May 2010. [Online]. Available: <https://vtechworks.lib.vt.edu/bitstream/handle/10919/55102/VT-2008-01.pdf>
- [31] H.-T. Fritzsche, 'A model for traffic simulation', *Traffic Eng. Control*, pp. 317–321, 1994.
- [32] J. Olstam and A. Tapani, 'Comparison of Car-following models', Swedish National Road Administration, 2004. [Online]. Available: <https://vti.diva-portal.org/smash/get/diva2:673977/FULLTEXT01.pdf>
- [33] V. Swathi, S. Yerraboina, G. Mallikarjun, and M. JhansiRani, 'Traffic Prediction for Intelligent Transportation System Using Machine Learning', in *2022 Second International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT)*, Bhilai, India: IEEE, Apr. 2022, pp. 1–4. doi: 10.1109/ICAECT54875.2022.9807652.
- [34] G. Meena, D. Sharma, and M. Mahrishi, 'Traffic Prediction for Intelligent Transportation System using Machine Learning', in *2020 3rd International Conference on Emerging Technologies in Computer Engineering: Machine Learning and Internet of Things (ICETCE)*, Jaipur, India: IEEE, Feb. 2020, pp. 145–148. doi:

10.1109/ICETCE48199.2020.9091758.

- [35] Y. Lv, Y. Duan, W. Kang, Z. Li, and F.-Y. Wang, 'Traffic Flow Prediction With Big Data: A Deep Learning Approach', *IEEE Trans. Intell. Transp. Syst.*, pp. 1–9, 2014, doi: 10.1109/TITS.2014.2345663.
- [36] B. M. Williams and L. A. Hoel, 'Modeling and Forecasting Vehicular Traffic Flow as a Seasonal ARIMA Process: Theoretical Basis and Empirical Results', *J. Transp. Eng.*, vol. 129, no. 6, pp. 664–672, Nov. 2003, doi: 10.1061/(ASCE)0733-947X(2003)129:6(664).
- [37] M. G. Karlaftis and E. I. Vlahogianni, 'Statistical methods versus neural networks in transportation research: Differences, similarities and some insights', *Transp. Res. Part C Emerg. Technol.*, vol. 19, no. 3, pp. 387–399, Jun. 2011, doi: 10.1016/j.trc.2010.10.004.
- [38] H. Yao, X. Tang, H. Wei, G. Zheng, and Z. Li, 'Revisiting Spatial-Temporal Similarity: A Deep Learning Framework for Traffic Prediction', *Proc. AAAI Conf. Artif. Intell.*, vol. 33, no. 01, pp. 5668–5675, Jul. 2019, doi: 10.1609/aaai.v33i01.33015668.
- [39] Y. Liu, H. Zheng, X. Feng, and Z. Chen, 'Short-term traffic flow prediction with Conv-LSTM', in *2017 9th International Conference on Wireless Communications and Signal Processing (WCSP)*, Nanjing: IEEE, Oct. 2017, pp. 1–6. doi: 10.1109/WCSP.2017.8171119.
- [40] K. Y. Chan, T. S. Dillon, J. Singh, and E. Chang, 'Neural-Network-Based Models for Short-Term Traffic Flow Forecasting Using a Hybrid Exponential Smoothing and Levenberg–Marquardt Algorithm', *IEEE Trans. Intell. Transp. Syst.*, vol. 13, no. 2, pp. 644–654, Jun. 2012, doi: 10.1109/TITS.2011.2174051.
- [41] S. Lu, Q. Zhang, G. Chen, and D. Seng, 'A combined method for short-term traffic flow prediction based on recurrent neural network', *Alex. Eng. J.*, vol. 60, no. 1, pp. 87–94, Feb. 2021, doi: 10.1016/j.aej.2020.06.008.
- [42] A. Abadi, T. Rajabioun, and P. A. Ioannou, 'Traffic Flow Prediction for Road Transportation Networks With Limited Traffic Data', *IEEE Trans. Intell. Transp. Syst.*, pp. 1–10, 2014, doi: 10.1109/TITS.2014.2337238.
- [43] W. Cheng, J. Li, H.-C. Xiao, and L. Ji, 'Combination predicting model of traffic congestion index in weekdays based on LightGBM-GRU', *Sci. Rep.*, vol. 12, no. 1, p. 2912, Feb. 2022, doi: 10.1038/s41598-022-06975-1.
- [44] R. Fu, Z. Zhang, and L. Li, 'Using LSTM and GRU neural network methods for traffic flow prediction', in *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*, Wuhan, Hubei Province, China: IEEE, Nov. 2016, pp. 324–328. doi: 10.1109/YAC.2016.7804912.
- [45] Z. Cui, K. Henrickson, R. Ke, and Y. Wang, 'Traffic Graph Convolutional

Recurrent Neural Network: A Deep Learning Framework for Network-Scale Traffic Learning and Forecasting', *IEEE Trans. Intell. Transp. Syst.*, vol. 21, no. 11, pp. 4883–4894, Nov. 2020, doi: 10.1109/TITS.2019.2950416.

- [46] X. Xu, T. Zhang, C. Xu, Z. Cui, and J. Yang, 'Spatial–Temporal Tensor Graph Convolutional Network for Traffic Speed Prediction', *IEEE Trans. Intell. Transp. Syst.*, vol. 24, no. 1, pp. 92–103, Jan. 2023, doi: 10.1109/TITS.2022.3215613.
- [47] L. Zhao *et al.*, 'T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction', *IEEE Trans. Intell. Transp. Syst.*, vol. 21, no. 9, pp. 3848–3858, Sep. 2020, doi: 10.1109/TITS.2019.2935152.
- [48] S. Guo, Y. Lin, N. Feng, C. Song, and H. Wan, 'Attention Based Spatial-Temporal Graph Convolutional Networks for Traffic Flow Forecasting', *Proc. AAAI Conf. Artif. Intell.*, vol. 33, no. 01, pp. 922–929, Jul. 2019, doi: 10.1609/aaai.v33i01.3301922.
- [49] J. Zhang, Y. Zheng, J. Sun, and D. Qi, 'Flow Prediction in Spatio-Temporal Networks Based on Multitask Deep Learning', *IEEE Trans. Knowl. Data Eng.*, vol. 32, no. 3, pp. 468–478, Mar. 2020, doi: 10.1109/TKDE.2019.2891537.
- [50] X. Luo, D. Li, Y. Yang, and S. Zhang, 'Spatiotemporal Traffic Flow Prediction with KNN and LSTM', *J. Adv. Transp.*, vol. 2019, pp. 1–10, Feb. 2019, doi: 10.1155/2019/4145353.
- [51] California Department of Transportation, 'Performance Measurement System (PeMS)'. [Online]. Available: <http://pems.dot.ca.gov>
- [52] Y. Li, R. Yu, C. Shahabi, and Y. Liu, 'Diffusion Convolutional Recurrent Neural Network: Data-Driven Traffic Forecasting', 2017, doi: 10.48550/ARXIV.1707.01926.
- [53] L. Mou, P. Zhao, H. Xie, and Y. Chen, 'T-LSTM: A Long Short-Term Memory Neural Network Enhanced by Temporal Information for Traffic Flow Prediction', *IEEE Access*, vol. 7, pp. 98053–98060, 2019, doi: 10.1109/ACCESS.2019.2929692.
- [54] C. Ma, Y. Zhao, G. Dai, X. Xu, and S.-C. Wong, 'A Novel STFSA-CNN-GRU Hybrid Model for Short-Term Traffic Speed Prediction', *IEEE Trans. Intell. Transp. Syst.*, vol. 24, no. 4, pp. 3728–3737, Apr. 2023, doi: 10.1109/TITS.2021.3117835.
- [55] X. Yin, G. Wu, J. Wei, Y. Shen, H. Qi, and B. Yin, 'Deep Learning on Traffic Prediction: Methods, Analysis, and Future Directions', *IEEE Trans. Intell. Transp. Syst.*, vol. 23, no. 6, pp. 4927–4943, Jun. 2022, doi: 10.1109/TITS.2021.3054840.
- [56] C. Ma, G. Dai, and J. Zhou, 'Short-Term Traffic Flow Prediction for Urban Road Sections Based on Time Series Analysis and LSTM_BILSTM Method', *IEEE Trans. Intell. Transp. Syst.*, vol. 23, no. 6, pp. 5615–5624, Jun. 2022, doi: 10.1109/TITS.2021.3055258.
- [57] Z. Wang, X. Su, and Z. Ding, 'Long-Term Traffic Prediction Based on LSTM Encoder-Decoder Architecture', *IEEE Trans. Intell. Transp. Syst.*, vol. 22, no. 10, pp.

6561–6571, Oct. 2021, doi: 10.1109/TITS.2020.2995546.

- [58] B. Ghosh, B. Basu, and M. O'Mahony, 'Multivariate Short-Term Traffic Flow Forecasting Using Time-Series Analysis', *IEEE Trans. Intell. Transp. Syst.*, vol. 10, no. 2, pp. 246–254, Jun. 2009, doi: 10.1109/TITS.2009.2021448.
- [59] L. Fei and B. Han, 'Multi-Object Multi-Camera Tracking Based on Deep Learning for Intelligent Transportation: A Review', *Sensors*, vol. 23, no. 8, p. 3852, Apr. 2023, doi: 10.3390/s23083852.
- [60] L. Qu, W. Li, W. Li, D. Ma, and Y. Wang, 'Daily long-term traffic flow forecasting based on a deep neural network', *Expert Syst. Appl.*, vol. 121, pp. 304–312, May 2019, doi: 10.1016/j.eswa.2018.12.031.
- [61] P. Trirat, S. Yoon, and J.-G. Lee, 'MG-TAR: Multi-View Graph Convolutional Networks for Traffic Accident Risk Prediction', *IEEE Trans. Intell. Transp. Syst.*, vol. 24, no. 4, pp. 3779–3794, Apr. 2023, doi: 10.1109/TITS.2023.3237072.
- [62] X. Ma, Z. Dai, Z. He, J. Ma, Y. Wang, and Y. Wang, 'Learning Traffic as Images: A Deep Convolutional Neural Network for Large-Scale Transportation Network Speed Prediction', *Sensors*, vol. 17, no. 4, p. 818, Apr. 2017, doi: 10.3390/s17040818.
- [63] Z. Cui, L. Lin, Z. Pu, and Y. Wang, 'Graph Markov network for traffic forecasting with missing data', *Transp. Res. Part C Emerg. Technol.*, vol. 117, p. 102671, Aug. 2020, doi: 10.1016/j.trc.2020.102671.
- [64] A. Wang, Y. Ye, X. Song, S. Zhang, and J. J. Q. Yu, 'Traffic Prediction With Missing Data: A Multi-Task Learning Approach', *IEEE Trans. Intell. Transp. Syst.*, vol. 24, no. 4, pp. 4189–4202, Apr. 2023, doi: 10.1109/TITS.2022.3233890.
- [65] I. Lana, J. Del Ser, M. Velez, and E. I. Vlahogianni, 'Road Traffic Forecasting: Recent Advances and New Challenges', *IEEE Intell. Transp. Syst. Mag.*, vol. 10, no. 2, pp. 93–109, 2018, doi: 10.1109/MITS.2018.2806634.
- [66] R. L. Abduljabbar, H. Dia, and P.-W. Tsai, 'Development and evaluation of bidirectional LSTM freeway traffic forecasting models using simulation data', *Sci. Rep.*, vol. 11, no. 1, p. 23899, Dec. 2021, doi: 10.1038/s41598-021-03282-z.
- [67] Q. Chen *et al.*, 'A deep neural network inverse solution to recover pre-crash impact data of car collisions', *Transp. Res. Part C Emerg. Technol.*, vol. 126, p. 103009, May 2021, doi: 10.1016/j.trc.2021.103009.
- [68] Y. Xie, C. T. Wu, B. Li, X. Hu, and S. Li, 'A feed-forwarded neural network-based variational Bayesian learning approach for forensic analysis of traffic accident', *Comput. Methods Appl. Mech. Eng.*, vol. 397, p. 115148, Jul. 2022, doi: 10.1016/j.cma.2022.115148.
- [69] B. Jiang and Y. Fei, 'Traffic and vehicle speed prediction with neural network and Hidden Markov model in vehicular networks', in *2015 IEEE Intelligent Vehicles Symposium (IV)*, Seoul, South Korea: IEEE, Jun. 2015, pp. 1082–1087. doi:

10.1109/IVS.2015.7225828.

- [70] M. Zhou, X. Qu, and X. Li, 'A recurrent neural network based microscopic car following model to predict traffic oscillation', *Transp. Res. Part C Emerg. Technol.*, vol. 84, pp. 245–264, Nov. 2017, doi: 10.1016/j.trc.2017.08.027.
- [71] X. Wang, R. Jiang, L. Li, Y. Lin, X. Zheng, and F.-Y. Wang, 'Capturing Car-Following Behaviors by Deep Learning', *IEEE Trans. Intell. Transp. Syst.*, vol. 19, no. 3, pp. 910–920, Mar. 2018, doi: 10.1109/TITS.2017.2706963.
- [72] F. Acun and E. A. Gol, 'Traffic Prediction on Large Scale Traffic Networks Using ARIMA and K-Means', in *2021 29th Signal Processing and Communications Applications Conference (SIU)*, Istanbul, Turkey: IEEE, Jun. 2021, pp. 1–4. doi: 10.1109/SIU53274.2021.9477817.
- [73] X. Liu, Y. Zhang, M. Yang, Z. Xue, and C. Ye, 'Traffic Flow Prediction via Weighted Combination of ARIMA and WASDNN Models', in *2021 33rd Chinese Control and Decision Conference (CCDC)*, Kunming, China: IEEE, May 2021, pp. 604–611. doi: 10.1109/CCDC52312.2021.9601830.
- [74] L. Szoke, S. Aradi, T. Becsi, and P. Gaspar, 'Driving on Highway by Using Reinforcement Learning with CNN and LSTM Networks', in *2020 IEEE 24th International Conference on Intelligent Engineering Systems (INES)*, Reykjavík, Iceland: IEEE, Jul. 2020, pp. 121–126. doi: 10.1109/INES49302.2020.9147185.
- [75] PTV Planung Transport Verkehr GmbH, 'PTV Vissim', *PTV-Group*, May 23, 2023. <https://www.ptvgroup.com/pl/rozwiazania/produkty/ptv-vissim/> (accessed Aug. 05, 2023).
- [76] K. Aghabayk, M. Sarvi, W. Young, and L. Kautzsch, 'A novel methodology for evolutionary calibration of Vissim by multi-threading', *Australas. Transp. Res. Forum*, vol. 36, no. 1, pp. 1–15, 2013.
- [77] N. Raju, P. Kumar, A. Chepuri, and S. S. Arkatkar, 'Calibration of vehicle following models using trajectory data under heterogeneous traffic conditions', presented at the Transportation Research Board 96th Annual Meeting Transportation Research, Washinton DC, USA, Jan. 2017. [Online]. Available: https://www.researchgate.net/profile/Narayana-Raju/publication/318053564_CALIBRATION_OF_VEHICLE_FOLLOWING_MODELS_USING_TRAJECTORY_DATA_UNDER_HETEROGENEOUS_TRAFFIC_CONDITIONS/links/5f0c32474585155a5524fc67/CALIBRATION-OF-VEHICLE-FOLLOWING-MODELS-USING-TRAJECTORY-DATA-UNDER-HETEROGENEOUS-TRAFFIC-CONDITIONS.pdf
- [78] Florida Department of Transportation, *Traffic Analysis Handbook. A Reference for Planning and Operations*. Florida Department of Transportation, 2014. [Online]. Available: <https://fdotwww.blob.core.windows.net/sitefinity/docs/default-source/planning/systems/systems-management/sm-old-files/traffic->

analysis/traffic-analysis-handbook_march-2014.pdf?sfvrsn=51c88e22_0

- [79] B. Higgs, M. M. Abbas, and A. Medina, 'Analysis of the Wiedemann car following model over different speeds using naturalistic data', presented at the RSS Conference, 2011. [Online]. Available: <https://onlinepubs.trb.org/onlinepubs/conferences/2011/RSS/3/Higgs,B.pdf>
- [80] A. Rahmi and M. Besley, 'Acceleration and deceleration models', presented at the 23rd Conference of Australian Institutes of Transport Research (CAITR 2001), Monash University, Melbourne, Australia, 2001. [Online]. Available: https://www.researchgate.net/profile/Rahmi-Akcelik/publication/238778191_Acceleration_and_deceleration_models/links/004635328134528aaa000000/Acceleration-and-deceleration-models.pdf
- [81] N. Kudarauskas, 'Analysis of emergency braking of a vehicle', *Transport*, vol. 22, no. 3, pp. 154–159, 2007, doi: 10.1080/16484142.2007.9638118.
- [82] A. Sroczyński, A. Kurowski, S. Zaporowski, and A. Czyżewski, 'Examining Impact of Speed Recommendation Algorithm Operating in Autonomous Road Signs on Minimum Distance between Vehicles', *Remote Sens.*, vol. 14, no. 12, p. 2803, Jun. 2022, doi: 10.3390/rs14122803.
- [83] K. Chen, M. Zhang, Y. Tang, J. Li, Y. Liu, and J. He, 'Impact of Visibility Classification Schemes on Traffic Efficiency in Intelligent Freeway Management Systems A Mechanism for all-Weather Transportation Services with Vehicle-Road Coordination Technology', in *2020 5th International Conference on Information Science, Computer Technology and Transportation (ISCTT)*, Shenyang, China: IEEE, Nov. 2020, pp. 650–653. doi: 10.1109/ISCTT51595.2020.00124.
- [84] F. Fakhfakh, M. Tounsi, and M. Mosbah, 'Vehicle Platooning Systems: Review, Classification and Validation Strategies', *Int. J. Networked Distrib. Comput.*, vol. 8, no. 4, p. 203, 2020, doi: 10.2991/ijndc.k.200829.001.
- [85] A. Pande, P. B. Wolshon, and Institute of Transportation Engineers, Eds., *Traffic engineering handbook*, Seventh edition. Hoboken, New Jersey: Wiley, 2015.
- [86] American Association of State Highway and Transportation Officials, Ed., *A policy on geometric design of highways and streets*, 2001, 4th ed. Washington, D.C.: American Association of State Highway and Transportation Officials, 2001.
- [87] *A Policy on geometric design of highways and streets*, 6th ed. Washington: AASHTO, 2011.
- [88] Y. D. García-Ramírez and D. Aguilar-Cárdenas, 'Passengers' comfort in horizontal curves on mountain roads: a field study using lateral accelerations', *Rev. Fac. Ing. Univ. Antioquia*, May 2020, doi: 10.17533/udea.redin.20200578.
- [89] J. Xu, K. Yang, Y. Shao, and G. Lu, 'An Experimental Study on Lateral Acceleration of Cars in Different Environments in Sichuan, Southwest China',

Discrete Dyn. Nat. Soc., vol. 2015, pp. 1–16, 2015, doi: 10.1155/2015/494130.

- [90] S. Goncu, I. G. Erdagi, M. A. Silgu, and H. B. Celikoglu, 'Analysis on Effects of Driving Behavior on Freeway Traffic Flow: A Comparative Evaluation of Two Driver Profiles Using Two Car-Following Models', in *2022 IEEE Intelligent Vehicles Symposium (IV)*, Aachen, Germany: IEEE, Jun. 2022, pp. 688–693. doi: 10.1109/IV51971.2022.9827296.
- [91] A. Sroczynski and A. Czyzewski, 'Examining the Impact of Distance Between VSL Road Signs on Vehicle Speed Variance', *IEEE Access*, vol. 11, pp. 7521–7529, 2023, doi: 10.1109/ACCESS.2023.3238578.
- [92] P. Warden and D. Situnayake, *TinyML: machine learning with TensorFlow Lite on Arduino and ultra-low-power microcontrollers*, First edition. Beijing Boston: O'Reilly, 2020.
- [93] S. Cygert and A. Czyzewski, 'Style Transfer for Detecting Vehicles with Thermal Camera', in *2019 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, Poznan, Poland: IEEE, Sep. 2019, pp. 218–222. doi: 10.23919/SPA.2019.8936707.
- [94] S. Cygert and A. Czyzewski, 'Vehicle detector training with labels derived from background subtraction algorithms in video surveillance', in *2018 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, Poznan: IEEE, Sep. 2018, pp. 98–103. doi: 10.23919/SPA.2018.8563368.
- [95] S. Cygert and A. Czyzewski, 'Vehicle Detection with Self-Training for Adaptive Video Processing Embedded Platform', *Appl. Sci.*, vol. 10, no. 17, p. 5763, Aug. 2020, doi: 10.3390/app10175763.
- [96] A. Czyzewski, J. Kotus, and B. Kostek, 'Sonda natężeniowa', Ru.070428, Jul. 03, 2018
- [97] J. Kotus, G. Szwoch, and A. Czyzewski, 'Sonda natężeniowa wraz z układem kalibracji', Pat.238832, Jul. 02, 2021
- [98] J. Kotus, G. Szwoch, A. Czyzewski, and B. Kostek, 'Assessment of road surface state with acoustic vector sensor', *J. Acoust. Soc. Am.*, vol. 152, no. 4_Supplement, pp. A193–A193, Oct. 2022, doi: 10.1121/10.0015995.
- [99] 'MetroCount: MC5600 Vehicle Classifier System'.
- [100] A. Czyzewski and A. Sroczynski, 'Comparing Traffic Intensity Estimates Employing Passive Acoustic Radar and Microwave Doppler Radar Sensor', presented at the 179th Meeting of the Acoustical Society of America, Acoustics Virtually Everywhere, 2020, p. 030001. doi: 10.1121/2.0001357.
- [101] J. Kotus and G. Szwoch, 'Calibration of acoustic vector sensor based on MEMS microphones for DOA estimation', *Appl. Acoust.*, vol. 141, pp. 307–321, Dec. 2018, doi: 10.1016/j.apacoust.2018.07.025.

- [102] G. Szwoch and J. Kotus, 'Detection of the incoming sound direction employing MEMS microphones and the DSP. In', presented at the 9th International Conference, MCSS 2017, , Kraków, Poland: Multimedia Communications, Services and Security: , Proceedings 9 (pp. 186-198). Springer International Publishing., Nov. 2017.
- [103] G. Szwoch and J. Kotus, 'Acoustic Detector of Road Vehicles Based on Sound Intensity', *Sensors*, vol. 21, no. 23, p. 7781, Nov. 2021, doi: 10.3390/s21237781.
- [104] A. Czyżewski, J. Kotus, and G. Szwoch, 'Estimating Traffic Intensity Employing Passive Acoustic Radar and Enhanced Microwave Doppler Radar Sensor', *Remote Sens.*, vol. 12, no. 1, p. 110, Dec. 2019, doi: 10.3390/rs12010110.
- [105] J. Kotus and G. Szwoch, 'Estimation of Average Speed of Road Vehicles by Sound Intensity Analysis', *Sensors*, vol. 21, no. 16, p. 5337, Aug. 2021, doi: 10.3390/s21165337.
- [106] G. Szwoch and A. Czyżewski, 'Sposób poprawy skuteczności analizy ruchu pojazdów drogowych na drogach dwukierunkowych i układ do stosowania tego sposobu', Pat.241169, May 24, 2022
- [107] G. Szwoch, 'Suppression of distortions in signals received from Doppler sensor for vehicle speed measurement', in *2018 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, Poznan: IEEE, Sep. 2018, pp. 16–21. doi: 10.23919/SPA.2018.8563403.
- [108] 'LoRa Alliance: What is LoRaWAN'. [Online]. Available: <https://loralliance.org/about-lorawan/>

Publikacje autora

Poniżej wymienione są artykuły których współautorem jest autor niniejszej rozprawy i które zostały opublikowane podczas trwania studiów doktoranckich.

- A. Czyżewski et al., "Comparative study on the effectiveness of various types of road traffic intensity detectors," 2019 6th International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS), Cracow, Poland, 2019, pp. 1-7, DOI: 10.1109/MTITS.2019.8883354.
- A. Czyżewski, A. Sroczyński, T. Śmiałkowski and P. Hoffmann, "Development of Intelligent Road Signs with V2X Interface for Adaptive Traffic Controlling," 2019 6th International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS), Cracow, Poland, 2019, pp. 1-7, DOI: 10.1109/MTITS.2019.8883369.
- A. Czyżewski, A. Sroczyński; Comparing Traffic Intensity Estimates Employing Passive Acoustic Radar and Microwave Doppler Radar Sensor. Proc. Mtgs. Acoust 11 December 2020; 42 (1): 030001. DOI: 10.1121/2.0001357
- A. Sroczyński,; A. Kurowski,; S. Zaporowski,; A. Czyżewski, . Examining Impact of Speed Recommendation Algorithm Operating in Autonomous Road Signs on Minimum Distance between Vehicles. Remote Sens. 2022, 14, 2803. DOI: 10.3390/rs14122803
- A. Sroczyński and A. Czyżewski, "Examining the Impact of Distance Between VSL Road Signs on Vehicle Speed Variance" in IEEE Access, vol. 11, pp. 7521-7529, 2023, DOI: 10.1109/ACCESS.2023.3238578.

Oprócz powyższych, na etapie recenzji w czasopiśmie Scientific Reports znajduje się artykuł:


- A. Sroczyński and A. Czyżewski, " Road traffic can be predicted by machine learning equally effectively as by complex microscopic model".

Pozostałe, niezwiązane z niniejszą rozprawą opublikowane ze współudziałem autora są następujące:


- A. Kurowski,; A. Sroczyński, ; G. Bogdanis, ; A. Czyżewski, An Automated Method for Biometric Handwritten Signature Authentication Employing Neural Networks. Electronics 2021, 10, 456. DOI: 10.3390/electronics10040456. Accessed on 17 Jun 2023.
- A. Czyżewski, , B. Kostek, , A. Kurowski. et al. Algorithmically improved microwave radar monitors breathing more accurate than sensorized belt. Sci Rep 12, 14412 (2022). DOI: 10.1038/s41598-022-18808-2. Accessed on 17 Jun 2023.

Dodatki


1. Wybrane rysunki konstrukcyjne




D1. IZD 4 x 6 paneli.




D2. IZD z otwartymi otworami rewizyjnymi i zdjętą pokrywą tylną.




D3. System mocowania czujników.




D4. Otwory laserowego czujnika pyłów.



D5. Elementy sterujące IZD.



D6. Czujnik wektorowej sondy akustycznej.



D7. Rysunek koncepcyjny IZD wraz z systemem zasilania wiatrowo-solarnego.

2. Patenty i nagrody

Autor znajduje się w gronie współlaureatów nagród przyznanych gdańskim naukowcom za opracowania, w których uczestniczyła firma Tstronic we współpracy z Politechniką Gdańską. Są to: Nagroda Badawcza Siemens, Godło Promocyjne Teraz Polska i Nagroda PARP/NCBR "Polski Produkt Przyszłości" oraz złoty medal przyznany na szesnastych Międzynarodowych Targach wynalazków i Innowacji INTARG 2023.

Autor rozprawy występuje jako współtwórca w następujących zgłoszeniach dotyczących patentów oraz wzorów przemysłowych:

1. Numer zgłoszenia: P.292854, numer prawa wyłącznego: Pat.166781
Nazwa/Tytuł: Sposób i układ do dyskryminacji połączeń telefonicznych
Zgłaszający/Uprawniony: DGT - Spółka Z Ograniczoną Odpowiedzialnością,
Twórcy: Andrzej Adler, Andrzej Sroczyński, Waław Czech
2. Numer zgłoszenia: P.307594, numer prawa wyłącznego: Pat.177306
Nazwa/Tytuł: Zintegrowany telekomunikacyjny układ sterowania
Zgłaszający/Uprawniony: DGT Spółka z Ograniczoną Odpowiedzialnością
Twórcy: Andrzej Kass, Andrzej Popowski, Waław Czech, Wojciech Łowiec,
Andrzej Sroczyński, Krzysztof Roźniak
3. Numer zgłoszenia: P.389637, Numer prawa wyłącznego: Pat.216114
Nazwa/Tytuł: Lampa uliczna z diodami świecącymi
Zgłaszający/Uprawniony: SILED Spółka z Ograniczoną Odpowiedzialnością
Twórcy: Andrzej Sroczyński, Radosław Bartłomiej Mioduski
4. Numer zgłoszenia: P.434083, Status: Postępowanie w toku
Nazwa/Tytuł: Stacja pomiarowa do wibroakustycznego monitorowania pracy maszyn elektrycznych zwłaszcza turbin wiatrowych
Zgłaszający/Uprawniony: Vis Energia Spółka z Ograniczoną Odpowiedzialnością
Twórcy: Andrzej Sroczyński, Andrzej Czyżewski
5. Numer zgłoszenia: W.129195, Numer prawa wyłącznego: Ru.072684
Nazwa/Tytuł: Stacja pomiarowa do wibroakustycznego monitorowania pracy maszyn elektrycznych zwłaszcza turbin wiatrowych
Zgłaszający/Uprawniony: Politechnika Gdańska
Twórcy: Andrzej Sroczyński, Andrzej Czyżewski
6. Numer zgłoszenia: Wp.28571, Numer prawa wyłącznego: Rp.26497
Nazwa/Tytuł: Płyta czołowa stacji pomiarowej do wibroakustycznego monitorowania pracy maszyn
Zgłaszający/Uprawniony: Politechnika Gdańska
Twórcy: Andrzej Sroczyński, Andrzej Czyżewski, Maciej Szczodrak
7. Numer zgłoszenia: Wp.28574, Numer prawa wyłącznego: Rp.26498
Nazwa/Tytuł: Sonda akustyczna z obudową

Zgłaszający/Uprawniony: Politechnika Gdańska

Twórcy: Andrzej Sroczyński, Andrzej Czyżewski, Józef Kotus

8. Numer zgłoszenia: Wp.30207, Numer prawa wyłącznego: Rp.27730

Nazwa/Tytuł: Bezkontaktowy monitor oddechowo-krażeniowy

Zgłaszający/Uprawniony: Politechnika Gdańska

Twórcy: Andrzej Sroczyński, Tomasz Śmiałkowski, Andrzej Czyżewski