



**Politechnika
Śląska**

POLITECHNIKA ŚLĄSKA

SZKOŁA DOKTORÓW

DYSCYPLINA NAUKOWA

INFORMATYKA TECHNICZNA I TELEKOMUNIKACJA

Rozprawa doktorska

Nowe algorytmy przetwarzania, analizy i oceny danych dla niestacjonarnych
systemów ważenia pojazdów w ruchu

Autor: mgr inż. Tomasz Konior

Promotor: prof. dr hab. inż. Jacek Izydorczyk

Gliwice, wrzesień 2024

Spis treści

1. Wprowadzenie.	5
1.1. Opis ogólny	5
1.2. Sformułowanie problemu badawczego.	7
1.3. Motywacja badawcza	9
1.4. Cel pracy	9
1.5. Tezy badawcze	9
1.6. Wyniki badań i oryginalny wkład.	10
1.7. Wkład dysertacji w kontekście prac pokrewnych.	11
1.8. Zarys rozprawy.	12
2. Opis systemów WIM	13
2.1. Przegląd powiązanych prac	13
2.2. Ważenie pojazdów w ruchu	18
2.2.1. Budowa stacji ważenia pojazdów w ruchu	18
2.2.2. Rodzaje stacji ważenia pojazdów w ruchu.	19
2.3. Przykładowa aplikacja agregująca dane	21
2.3.1. Integracja z rządowymi bazami danych.	22

2.4. Wdrożenie systemów HS-WIM-E: znaczenie i korzyści	23
2.5. Rodzaje systemów ważenia pojazdów	23
2.5.1. Wagi statyczne	23
2.5.2. Wagi dynamiczne (WIM)	24
2.6. Komponenty i technologie w systemach WIM.	26
2.7. Czujniki detekcji pojazdów	26
2.7.1. Rodzaje czujników w systemach WIM	28
2.8. Czujniki do ważenia pojazdów w ruchu	30
2.8.1. Czujniki światłowodowe	31
2.8.2. Czujniki pojemnościowe	31
2.8.3. Czujniki piezoelektryczne	31
2.8.4. Czujniki kwarcowe	32
2.8.5. Czujniki tensometryczne	32
2.9. Komputer wagowy	32
2.9.1. Częstotliwość próbkowania i przetwarzanie sygnałów	33
2.9.2. Integracja i analiza sygnałów.	34
2.10. Inne źródła danych.	34
2.10.1. Skaner 3D - LiDAR	35
2.10.2. Kamery pogładowe i ANPR.	35
2.11. Sygnały otrzymywane z stacji ważenia pojazdów w ruchu.	36
2.12. Algorytmy służące do przetwarzania sygnałów z czujników WIM	37
2.12.1. Metoda szczytowego napięcia	38
2.12.2. Metoda powierzchni pod sygnałem.	38
2.12.3. Metoda re-samplingu powierzchni	39

2.13. Algorytmy służące do przetwarzania sygnałów z czujników indukcyjnych pętlowych	39
2.13.1. Algorytm prostej detekcji	39
2.13.2. Algorytm detekcji szczytów	40
2.13.3. Algorytm filtracji sygnału	40
2.13.4. Algorytm analizy czasowo-amplitudowej	40
2.13.5. Pułapka pętli do sprawdzania prędkości pojazdu	40
2.14. Opis analizy sygnałów z pętli indukcyjnych	41
2.14.1. Pierwszy wektor cech profilu magnetycznego pojazdu	44
2.14.2. Drugi wektor cech profilu magnetycznego pojazdu	53
2.14.3. Trzeci wektor cech profilu magnetycznego pojazdu – estymacja prędkości pojazdu	55
2.14.4. Czwarty wektor cech profilu magnetycznego – estymacja liczby osi i długości pojazdu	58
2.15. Analiza czynnikowa wektorów cech	59
2.15.1. Analiza składowych głównych (PCA)	59
2.15.2. Analiza składowych niezależnych (ICA)	60
2.15.3. Analiza czynnikowa (FA).	60
2.16. Klasyfikatory, regresory oraz inne algorytmy analizy sygnałów z pętli indukcyjnych	61
2.16.1. Przegląd zastosowanych algorytmów	61
2.17. Analiza sygnałów z wag	65
2.17.1. Próbkowanie sygnału	66
2.17.2. Definicja okna trójkątnego	66

2.17.3.	Wygładzanie sygnału	67
2.17.4.	Rozszerzenie wygładzonego sygnału	67
2.17.5.	Normalizacja sygnału	67
2.17.6.	Metody odczytu masy	67
2.18.	Ocena dokładności ważenia pojazdów w ruchu.	70
2.19.	Klasyfikacja pojazdów	71
2.20.	Środowiska operacyjne oraz platformy sprzętowe	71
2.20.1.	ARK-2121	71
2.20.2.	ARK-1123	72
2.20.3.	Raspberry Pi Pico.	73
2.21.	Podsumowanie części teoretycznej.	73
2.21.1.	Przegląd literatury	73
2.21.2.	Podstawy teoretyczne	74
2.21.3.	Założenia badawcze.	74
2.21.4.	Wnioski	75
2.21.5.	Przyszłe kierunki badań	75
3.	Eksperymenty i wdrożenia.	77
3.1.	Stanowiska badawcze i wdrożeniowe	77
3.1.1.	Opis stanowiska badawczego 1	77
3.1.2.	Stanowisko wdrożeniowe 1	78
3.1.3.	Stanowisko badawcze 2	78
3.1.4.	Stanowisko wdrożeniowe 2	82

3.2. Badania dotyczące sygnałów z pętli indukcyjnych	82
3.2.1. Automatyczna klasyfikacja pojazdów	86
3.2.2. Estymacja długości pojazdu – podejście 1.	86
3.2.3. Klasyfikator rozpoznający liczbę osi – podejście 1	89
3.2.4. Klasyfikacja pojazdów na podstawie sygnałów z pętli – podejście 1	89
3.2.5. Klasyfikacja pojazdów na podstawie sygnałów z pętli – podejście 2	92
3.2.6. Klasyfikacja pojazdów na podstawie sygnałów z pętli – podejście 3	95
3.2.7. Estymator prędkości pojazdu – podejście 2	100
3.3. Badania dotyczące sygnałów z czujników wagowych	102
3.3.1. Klasyfikacja na podstawie czujników wagowych - podejście 1	102
3.3.2. Klasyfikacja na podstawie czujników wagowych – podejście 2	104
3.3.3. Ocena wiarygodności wyników ważenia pojazdów w ruchu.	105
3.3.4. Estymacja wagi pojazdu.	118
3.4. Eksploracja profilu magnetycznego pojazdu	123
3.4.1. Klasyfikacja modelu i marki pojazdu	123
4. Podsumowanie	135
4.1. Zwiększenie funkcjonalności stacji WIM poprzez algorytmny przetwarzania sygnałów	135
4.2. Wykorzystanie stacji WIM do celów administracyjnych za pomocą odpo- wiednich algorytmów	136
4.3. Transferowalność i adaptacyjność algorytmów WIM	136
4.4. Podsumowanie oryginalnego wkładu autora	136

5. Zestawy danych	139
5.1. Dane z pętli indukcyjnych szerokich z drogi krajowej 44.	139
5.1.1. Profile magnetyczne uzyskiwane na stacji.	140
5.2. Dane z pętli indukcyjnych szerokich i wąskich z układu akwizycji danych AGH.	143
5.2.1. Profile magnetyczne uzyskiwane na stacji AGH	144
5.3. Dane RAW z czujników ważenia pojazdów w ruchu	148
6. Narzędzia programowe i kody	151
Bibliografia	164

Wstęp

Wykorzystanie systemów ważenia pojazdów w ruchu (WIM ang. Weigh-in-Motion) do celów administracyjnych jest technicznie możliwe, ponieważ czujniki instalowane w drogach spełniają bardzo wysokie standardy, a otrzymywane wyniki są niemal identyczne z tymi, które uzyskuje się na legalizowanych systemach metrologicznych do pomiaru masy. Prace, które pozostają do wykonania w celu ostatecznego wdrożenia systemów ważenia pojazdów w ruchu (WIM ang. Weigh-in-Motion) do celów administracyjnych, dotyczą głównie kilku kluczowych obszarów: odpowiedniej klasyfikacji pojazdów, udoskonalenia metod odczytu informacji dotyczących pojazdów na podstawie zebranych sygnałów, klasyfikacji przewożonego ładunku oraz oceny wiarygodności pomiarów.

W niniejszej pracy autor, zarówno samodzielnie, jak i uczestnicząc w różnych grupach badawczych, podejmował próby rozwijania i proponowania nowych algorytmów przetwarzania oraz analizy sygnałów zebranych na stacjach ważenia pojazdów w ruchu. Opracowane algorytmy koncentrują się głównie na dwóch typach czujników: czujnikach nacisku zainstalowanych w nawierzchni drogi oraz pętlach indukcyjnych, również zainstalowanych w nawierzchni. Celem tych prac było zwiększenie precyzji i wiarygodności systemów ważenia pojazdów w ruchu (WIM ang. Weigh-in-Motion), co jest niezbędne do ich skutecznego zastosowania w kontekście administracyjnym.

Podziękowania

Niniejsza praca nie powstałaby bez wsparcia i współpracy wielu instytucji oraz osób, którym pragnę wyrazić serdeczne podziękowania.

Przede wszystkim chciałbym wyrazić wdzięczność Politechnice Śląskiej, gdzie realizuję studia doktoranckie i gdzie będę bronił niniejszą pracę doktorską. Szczególne podziękowania kieruję do mojego promotora, prof. dr hab. inż. Jacka Izydorczyka, który nieustannie wspierał mnie swoją wiedzą, doświadczeniem oraz cennymi radami. Jego wskazówki i uwagi były nieocenione na każdym etapie mojej pracy.

Chciałbym również podziękować współpracownikom z firmy APM PRO sp. z o.o., gdzie realizowałem doktorat wdrożeniowy. Ich wsparcie, zaangażowanie i możliwość praktycznego zastosowania badań były kluczowe dla osiągnięcia wyników zaprezentowanych w niniejszej pracy.

Podziękowania kieruję także do Uniwersytetu Bielsko-Bialskiego za owocną współpracę, której efektem były wspólne artykuły naukowe. Pomoc i zaangażowanie zespołu badawczego znacząco przyczyniły się do rozwoju niniejszej dysertacji.

Specjalne podziękowania składam Akademii Górniczo-Hutniczej w Krakowie oraz Panu dr inż. Zbigniewowi Marszałkowi za wsparcie w zakresie badań nad pętlami indukcyjnymi.

Nie mogę pominąć firmy Intercomp, której wsparcie oraz współpraca zaowocowały wspólnymi badaniami. Wasza otwartość i profesjonalizm były dla mnie inspiracją i motywacją do dalszej pracy.

Chciałbym również podziękować organizacji International Society for Weigh-in-Motion (ISWIM) za umożliwienie dostępu do najnowszych badań i technologii w zakresie ważenia pojazdów. Wasze zasoby i społeczność ekspertów były dla mnie bezcenne.

Na koniec, pragnę podziękować Komitetu ds. Architektury i Standaryzacji ITS organizowanemu przez stowarzyszenie ITS Polska za możliwość uczestnictwa oraz tworzenia opisu wspólnych standardów dla systemów ważenia pojazdów w ruchu w Polsce. Wasze spotkania

i dyskusje dostarczyły mi wielu cennych informacji i inspiracji, które znalazły swoje odzwierciedlenie w tej pracy.

Dziękuję wszystkim wymienionym instytucjom oraz osobom za wsparcie, współpracę i zaangażowanie, które przyczyniły się do powstania tej pracy.

Szczególne podziękowania kieruję również do mojej rodziny, która przez cały ten intensywny okres okazywała mi cierpliwość i wsparcie.

Niniejsze badania były współfinansowane przez Ministerstwo Edukacji i Nauki w ramach grantu nr DWD/4/21/2020 oraz dzięki firmie APM PRO Sp. z o.o.

1. Wprowadzenie

1.1. Opis ogólny

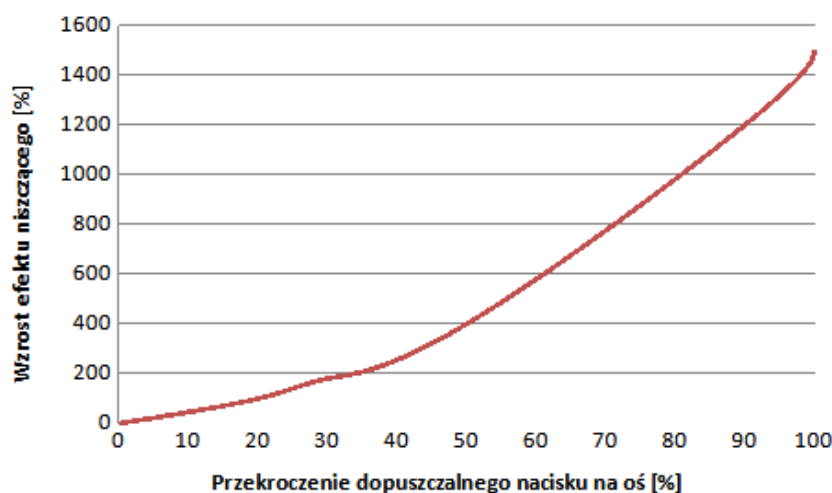
Przeciążone pojazdy poruszające się po drogach publicznych mają poważny i długotrwały wpływ na infrastrukturę drogową, w tym zarówno na jezdnie, jak i inżynieryjne obiekty drogowe, takie jak mosty i wiadukty. Badania wykazały, że nawet niewielkie, 10-procentowe przekroczenie dopuszczalnych nacisków osi może skutkować aż 45-procentowym wzrostem efektu niszczącego nawierzchnię [17]. w związku z tym skuteczną eliminacją przeciążonych pojazdów z ruchu drogowego staje się kluczowym czynnikiem w ochronie istniejącej infrastruktury, zwłaszcza w kontekście wysokich kosztów związanych z budową i remontami dróg. Z ekonomicznego i inżynieryjnego punktu widzenia, bardziej opłacalne jest zapobieganie degradacji infrastruktury niż kosztowne odbudowy.

W Polsce, gdzie natężenie ruchu oraz masy poruszających się pojazdów są znaczne, problem przeciążonych pojazdów nabiera szczególnego znaczenia. Analizy przeprowadzone na podstawie danych z 12 polskich stacji ważenia pojazdów w ruchu (WIM ang. Weigh-in-Motion) wykazały, że średni odsetek pojazdów przeciążonych na drogach o dużym natężeniu ruchu wynosi od 14% do 23%, a te pojazdy są odpowiedzialne za 35% do 70% uszkodzeń zmęczeniowych nawierzchni [90].

Na rys. 1.1 przedstawiono wpływ przeciążonych pojazdów na infrastrukturę drogową, podkreślając ich znaczący udział w degradacji nawierzchni. Z tych powodów wprowadzenie skutecznych systemów monitorowania i eliminacji przeciążeń w transporcie drogowym jest kluczowe dla zachowania integralności i wydłużenia czasu eksploatacji infrastruktury drogowej.

Jednym z istotnych aspektów pogłębiających problem przeciążenia pojazdów jest stosowanie opon typu Super Single w pojazdach ciężarowych, przyczepach i naczepach. Chociaż opony te są lepsze i oferują mniejszy opór toczenia, mają również mniejszą powierzchnię styku

1. Wprowadzenie



Rysunek 1.1. Wzrost efektu niszcącego przy przekroczeniu dopuszczalnego nacisku na oś.
Źródło: z pracy [17]

z nawierzchnią w porównaniu do tradycyjnych opon podwójnych, co prowadzi do szybszej degradacji dróg. Oprócz negatywnego wpływu na infrastrukturę drogową, przeciążone pojazdy stanowią poważne zagrożenie dla bezpieczeństwa ruchu drogowego, ponieważ przyczyniają się do ograniczenia sterowności, wydłużenia drogi hamowania oraz obniżenia komfortu jazdy, co w efekcie prowadzi do większego zmęczenia kierowców [4, 51].

W niniejszej pracy skoncentrowano się na rozwijaniu nowych algorytmów przetwarzania, analizy i oceny danych uzyskiwanych z niestacjonarnych systemów ważenia pojazdów w ruchu (WIM ang. Weigh-in-Motion), mających na celu zwiększenie efektywności identyfikacji pojazdów przeciążonych. Jest to kluczowe dla wdrożenia bardziej skutecznych systemów administracyjnych, które będą zdolne do automatycznego i ciągłego monitorowania stanu pojazdów w ruchu. Opracowanie takich rozwiązań umożliwi nie tylko bieżące wykrywanie przeciążeń, ale również pozwoli na szybkie wszczynanie procedur administracyjnych, co może znacząco przyczynić się do poprawy stanu infrastruktury drogowej oraz zwiększenia ogólnego bezpieczeństwa w ruchu drogowym.

Obecnie stosowane przez Inspekcję Transportu Drogowego (ITD) procedury, które opierają się głównie na statycznym ważeniu pojazdów, są wysoce nieefektywne. Przy założeniu, że przez punkt kontrolny przejeżdża dziennie około 1600 pojazdów ciężarowych, z czego 10% stanowią pojazdy przeciążone, jedynie 2-3% z nich jest faktycznie kontrolowanych. Przykładowe statystyki ze stacji ważenia pojazdów, uzyskane w ciągu doby, zostały przedstawione na rys. 1.2

1.2. Sformułowanie problemu badawczego

oraz rys. 1.3. w odpowiedzi na te wyzwania, w pracy zaproponowano wykorzystanie zaawansowanych technik analizy danych i algorytmów uczenia maszynowego do opracowania modeli predykcyjnych i klasyfikacyjnych, które mogą znacząco poprawić efektywność monitorowania przeciążeń w transporcie drogowym.

Praca ma charakter interdyscyplinarny, łącząc wiedzę z zakresu informatyki technicznej, inżynierii drogowej oraz analizy danych, co pozwala na holistyczne podejście do problemu przeciążeń w transporcie drogowym. Tego rodzaju integracja różnych dziedzin stanowi istotny krok w kierunku budowy inteligentnych systemów transportowych, które są zdolne do adaptacji i reagowania na dynamicznie zmieniające się warunki ruchu drogowego.


1.2. Sformułowanie problemu badawczego

Stacje ważenia pojazdów w ruchu (WIM ang. Weigh-in-Motion) stanowią wyjątkowe wyzwanie badawcze ze względu na ich dynamiczny charakter. Czujniki wagowe, pętle indukcyjne oraz inne urządzenia zintegrowane z nawierzchnią drogi tworzą system, którego właściwości ulegają ciągłym zmianom, na przykład pod wpływem zmian pogody. Ta niestacjonarność systemów WIM, objawiająca się chaotycznymi fluktuacjami właściwości w czasie, musi być uwzględniona podczas opracowywania algorytmów przetwarzania danych. Algorytmy, które sprawdzają się w jednym okresie, mogą okazać się niewystarczające w innym ze względu na zmienione warunki eksploatacyjne lub zróżnicowane warunki techniczne w różnych lokalizacjach [16].


Dodatkowym wyzwaniem jest konieczność implementacji tych systemów jako systemów czasu rzeczywistego, co wiąże się z wymaganiami dotyczącymi szybkości akwizycji, przetwarzania i analizy danych. W wielu przypadkach, ograniczony dostęp do sieci Ethernet lub jej brak, charakterystyczny dla lokalizacji stacji ważenia pojazdów w ruchu (WIM), komplikuje wykorzystanie rozwiązań opartych na chmurze obliczeniowej, co dodatkowo utrudnia proces przetwarzania danych.

Wobec powyższych wyzwań, kluczowym problemem badawczym w obszarze stacji ważenia pojazdów w ruchu (WIM) jest rozwój efektywnych metod identyfikacji niestacjonarności tych systemów. Głównym celem badawczym jest opracowanie zaawansowanych algorytmów przetwarzania danych, które będą odporne na zmienność warunków eksploatacyjnych, zapewniając jednocześnie wiarygodność pomiarów w czasie rzeczywistym. Opracowanie takich systemów WIM, które są skuteczne i niezawodne nie tylko w kontrolowanych warunkach laboratoryjnych,

1. Wprowadzenie



Rysunek 1.2. Mediana masy pojazdów powyżej 42 ton w ciągu doby – dane z przykładowej stacji WIM. Źródło: materiały firmy APM PRO



Rysunek 1.3. Liczba pojazdów powyżej 42 ton w ciągu doby – dane z przykładowej stacji WIM. Źródło: materiały firmy APM PRO

1.3. Motywacja badawcza

ale przede wszystkim w rzeczywistych warunkach drogowych, wymaga uwzględnienia specyficznych zmiennych środowiskowych i operacyjnych, takich jak zmiany temperatury, rodzaj używanej mieszanki bitumicznej, a także ograniczenia infrastrukturalne związane z dostępem do sieci.

1.3. Motywacja badawcza

Opracowanie odpowiednich algorytmów przetwarzania i analizy sygnałów ze stacji ważenia pojazdów w ruchu (WIM) jest kluczowym krokiem w kierunku wdrożenia systemów administracyjnych. Obecnie, mimo intensywnych kontroli prowadzonych przez Inspekcję Transportu Drogowego (ITD) w Polsce, przeciążone pojazdy nadal stanowią poważny problem. W związku z tym istnieje potrzeba wprowadzenia automatycznych systemów pomiaru i inicjowania procedur administracyjnych. Tego typu rozwiązanie pozwoliłoby na ograniczenie ruchu przeciążonych pojazdów na drogach, co bezpośrednio mogłoby przełożyć się na zwiększenie bezpieczeństwa ruchu drogowego oraz zmniejszenie zniszczeń infrastruktury drogowej spowodowanych przez przeciążone pojazdy.

1.4. Cel pracy

Głównym celem niniejszej dysertacji jest przeprowadzenie dogłębnej analizy, przetwarzania oraz oceny danych uzyskanych z niestacjonarnych systemów ważenia pojazdów w ruchu (WIM). Praca skupia się na badaniu i rozwijaniu zaawansowanych metod przetwarzania sygnałów pochodzących z czujników funkcjonujących w różnorodnych warunkach drogowych. Przy czym same czujniki podatne są zmiany środowiskowe i operacyjne. Celem jest opracowanie skutecznych technik, które umożliwią niezawodne funkcjonowanie systemów ważenia pojazdów w ruchu (WIM) w zmiennych warunkach, zapewniając ich efektywne i dokładne działanie w zastosowaniach praktycznych.

1.5. Tezy badawcze

W ramach pracy doktorskiej postawiono następujące tezy badawcze:

1. Wprowadzenie

1. Odpowiednio dobrane i zaprojektowane algorytmy przetwarzania sygnałów z czujników mogą znacząco zwiększyć funkcjonalność stacji ważenia pojazdów w ruchu, bez konieczności istotnej rozbudowy infrastruktury fizycznej.
2. Zastosowanie odpowiednich algorytmów oraz oprogramowania do przetwarzania danych umożliwia uruchomienie stacji ważenia pojazdów w ruchu do celów administracyjnych.
3. Istnieją algorytmy przetwarzania sygnałów, które zastosowane w przypadku niestacjonarnych systemów ważenia pojazdów w ruchu (WIM) wykazują wysoką odporność na zmieniające się warunki operacyjne i środowiskowe.

W ramach niniejszej pracy opracowane metody zostały poddane szczegółowej analizie i testom, aby ocenić ich skuteczność w rzeczywistych warunkach użytkowania oraz ich zdolność do generalizacji na różne warunki eksploatacyjne. Przeprowadzone badania miały na celu zweryfikowanie, czy zaproponowane rozwiązania spełniają założenia postawionych tez i czy mogą one zostać skutecznie wdrożone w praktyce.

1.6. Wyniki badań i oryginalny wkład

Niniejsza praca jest w całości indywidualnym dziełem autora, jednakże niektóre tezy oraz badania zostały opracowane i przeprowadzone w ramach zespołów badawczych, w których autor uczestniczył. w związku z tym, te tezy i badania nie stanowią jego wyłącznego wkładu. Starano się jednak dokładnie określić oryginalny wkład autora w każdym z rozdziałów, co zostało przedstawione poniżej.

Oryginalny wkład autora obejmujący zaproponowanie metod, projektowanie, badania, tworzenie, testy, opis oraz wdrożenie:

1. Regresorów do estymacji długości pojazdu: podejście 1 (rozdział 3.2.2) oraz podejście 2 (rozdział 3.2.7).
2. Klasyfikatora do określania liczby osi pojazdu (rozdział 3.2.3).
3. Klasyfikatorów pojazdów na podstawie sygnałów z pętli indukcyjnych: podejście 1 (rozdział 3.2.4) oraz podejście 2 (rozdział 3.2.5).
4. Metody estymacji wagi pojazdu na podstawie sygnałów z czujników wagowych (rozdział 3.3.4).
5. Klasyfikatora modelu i marki pojazdu na podstawie profilu magnetycznego (rozdział 3.4.1).

Oryginalny wkład autora jako jednego z głównych autorów w zespole badawczym, obejmujący zaproponowanie metod, projektowanie, badania, tworzenie, testy oraz opis:

1.7. Wkład dysertacji w kontekście prac pokrewnych

1. Klasyfikatora pojazdów na podstawie sygnałów z pętli indukcyjnych - podejście 3 (rozdział 3.2.6).

Oryginalny wkład autora jako autora pomocniczego w zespole badawczym, obejmujący implementację, badania, testy, opis, wdrożenie oraz analizę statystyczną po wdrożeniu:

1. Klasyfikacja na podstawie sygnałów z czujników wagowych: podejście 1 (rozdział 3.3.1) oraz podejście 2 (rozdział 3.3.2).
2. Badania nad nowymi algorytmami do oceny wiarygodności pomiarów na podstawie ważenia pojazdów w ruchu (rozdział 3.3.3).

1.7. Wkład dysertacji w kontekście prac pokrewnych

Niniejsza praca stanowi rozwinięcie dotychczasowych badań nad analizą sygnałów pochodzących z systemów ważenia pojazdów w ruchu. W szczególności, w nawiązaniu do prac takich jak [74], gdzie przedstawiono metodę obliczeniową wyznaczania prędkości pojazdu na podstawie sygnału z pojedynczej pętli indukcyjnej, zaproponowano zastosowanie algorytmów uczenia maszynowego, co pozwoliło na uzyskanie lepszych wyników. Kolejnym przykładem jest praca [98], w której zaproponowano wektor cech do klasyfikacji za pomocą metod uczenia maszynowego. Wektor ten został również zastosowany w niniejszej pracy, a dodatkowo opracowano podejście polegające na wykorzystaniu sygnałów z pętli indukcyjnej o zmienionej geometrii oraz różnych częstotliwościach wzbudzenia. Ponadto, wprowadzono dodatkowe algorytmy uczenia maszynowego, w tym wykorzystanie sieci neuronowych, co przyczyniło się do poprawy wyników w porównaniu z pierwotnie proponowanym układem i algorytmami. Klasyfikację pojazdów na podstawie sygnałów z pojedynczej pętli opisano również w pracy [15]. W kontekście tej pracy rozszerzono możliwości klasyfikacji systemu poprzez zastosowanie metod uczenia maszynowego.

W odniesieniu do klasycznie opisanych metod oceny niepewności pomiarowych [32], zaproponowano algorytm dynamicznej oceny niepewności pomiarowych dla każdego z pomiarów. W nawiązaniu do pracy [60], w której opisano trzy metody estymacji wagi pojazdu na podstawie sygnałów z czujników wagowych, przedstawiono metodę estymacji opartą na metodach uczenia maszynowego. Odnosząc się do pracy [91], zaproponowano metody wykorzystania danych z czujników ważenia zamontowanych w nawierzchni drogi do klasyfikacji pojazdów. Na zakończenie, wykorzystując zdobytą wiedzę, zaproponowano metodę rozpoznawania modelu i marki pojazdu na podstawie sygnału z pojedynczej pętli indukcyjnej zamontowanej w nawierzchni drogi, z wykorzystaniem podejścia opisanego w pracy [43].

1.8. Zarys rozprawy

Niniejsza rozprawa została podzielona na dwie główne części: teoretyczną oraz eksperymentalną. w części teoretycznej zawarto szczegółowe opisy wektorów cech wykorzystywanych do tworzenia klasyfikatorów, a także wzory matematyczne i algorytmy. Natomiast w części eksperymentalnej skoncentrowano się na opisie przeprowadzonych eksperymentów i omówieniu uzyskanych wyników, pomijając szczegółowe wyjaśnienia teoretyczne. Decyzja o rozdzieleniu teorii od praktyki została podjęta w celu zachowania przejrzystości prezentowanych eksperymentów, co według autora zwiększa czytelność i klarowność rozprawy.

Struktura pracy obejmuje sześć części:

1. **Wprowadzenie:** w tej części zawarto ogólny opis problemu badawczego, cele badawcze oraz sformułowane tezy.
2. **Opis systemów WIM:** przedstawiono przegląd literatury, opisano budowę stacji ważenia pojazdów w ruchu oraz scharakteryzowano czujniki i urządzenia będące źródłem danych na stacjach ważenia pojazdów w ruchu (WIM). Zawarto również metody analizy i przetwarzania sygnałów z poszczególnych czujników, w tym szczegółowe omówienie wektorów cech, metod uczenia maszynowego oraz innych algorytmów wraz z pseudokodami.
3. **Eksperymenty i wdrożenia:** zawiera opis:
 - stanowiska badawczego i wdrożeniowego;
 - badań oraz omówienie wyników przetwarzania i analizy sygnałów z pętli indukcyjnych oraz czujników wagowych. Przedstawiono także koncepcje badań, które wymagają dalszego rozwinięcia i analizy.
4. **Podsumowanie:** w tej części podsumowano uzyskane wyniki i przeanalizowano je w kontekście postawionych tez badawczych.
5. **Zestaw danych:** zawarto przykładowe zestawy danych, które zostały wykorzystane w ramach niniejszej pracy.
6. **Opis narzędzi programowych i kodów:** wymieniono i opisano użyte biblioteki oraz programy, które zostały zastosowane podczas realizacji pracy.

2. Opis systemów WIM

2.1. Przegląd powiązanych prac

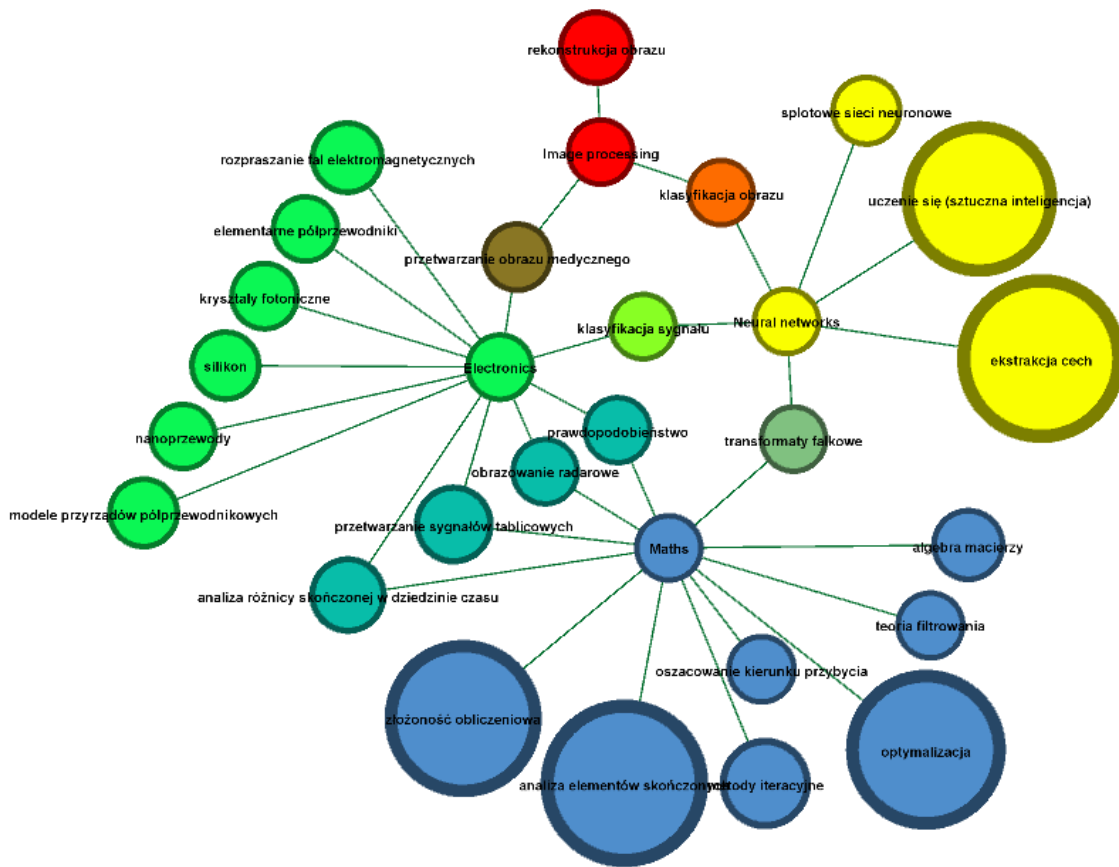
Systemy Ważenia w Ruchu (WIM) są w wielu krajach podstawowym narzędziem do monitorowania przeciążonych pojazdów na drogach. Umożliwiają one szybką selekcję takich pojazdów, a także dostarczają innych istotnych danych o ruchu drogowym. Ze względu na rosnące wymagania wobec tych systemów, na całym świecie prowadzi się liczne badania naukowe i prace rozwojowe, mające na celu ich doskonalenie. Badania te dotyczą zarówno ogólnej koncepcji systemów WIM, jak i poszczególnych ich komponentów.

W ramach rozpoznania problemu badawczego wykonano przegląd elementów, z których składa się system WIM oraz wykonano przegląd literatury, w ramach którego wskazano tematy wykazujące największy potencjał badawczy związany z stacjami ważenia pojazdów w ruchu. Podsumowanie przeglądu można zobaczyć na rys. 2.1.

Najbardziej obiecująca wydawała się dziedzina algorytmów dotyczących przetwarzania „surowych” sygnałów, które dostarczają wybrane czujniki stacji WIM. Są to sygnały jakie otrzymujemy z pętli indukcyjnych i czujników ważenia. Pozostałe czujniki w ramach stacji WIM dostarczają danych przetworzonych jak np. stacja meteo czy kamery. Wprawdzie w ramach przeprowadzonych prac opracowano oprogramowanie do odczytu tablic rejestracyjnych bazujące na sieciach neuronowych oraz program prognozujący krótkoterminowo stan nawierzchni na podstawie odczytów ze stacji meteo, nie były to jednak najbardziej innowacyjne z wykonanych prac. W związku z tym zdecydowano nie opisywać tych zagadnień.

W systemach WIM (*Weigh-In-Motion*) do wykrywania pojazdów oraz ich klasyfikacji szeroko stosuje się pętle indukcyjne oraz czujniki magnetyczne. Pętle indukcyjne są wykorzystywane nie tylko do wykrywania obecności pojazdów, ale również do określania ich prędkości i długości, co czyni je szczególnie przydatnymi na stacjach WIM. Najczęściej stosowanym

2. Opis systemów WIM



Rysunek 2.1. Zestawienie kierunków badawczych związanych z stacjami ważenia pojazdów w ruchu. Źródło: opracowanie własne

rozwiązaniem jest układ podwójnych pętli indukcyjnych, choć istnieją także bardziej zaawansowane systemy z większą liczbą pętli, jak na przykład system Fareco [52]. Rejestrowany profil magnetyczny pojazdu pozwala na klasyfikację pojazdu do określonych kategorii, co ma znaczenie zarówno dla kontroli masy pojazdów, jak i dla analizy struktury ruchu drogowego. Proces klasyfikacji opiera się na transformacji profilu zarejestrowanego w domenie czasu, uwzględniając długość pojazdu [15]. Praca [39] opisuje proces klasyfikacji pojazdów do czterech głównych kategorii na podstawie parametrów wyznaczanych z profilu magnetycznego. W badaniach przeprowadzonych w Kalifornii [23] analizowano skuteczność klasyfikacji pojazdów poprzez porównanie profilu magnetycznego z bazą profili wzorcowych. W pracy [45] zastosowano połączenie informacji z pętli indukcyjnych oraz czujników wagowych do klasyfikacji pojazdów ciężarowych.

2.1. Przegląd powiązanych prac

W ostatnich latach prowadzone są prace nad zastąpieniem klasycznego układu z dwoma pętlami indukcyjnymi bardziej kompaktowymi rozwiązaniami. W badaniu [25] wykazano, że skuteczność klasyfikacji pojazdów za pomocą pojedynczej pętli indukcyjnej może dorównywać rozwiązaniom z dwoma pętlami. W pracy [61] zaproponowano nową metodę klasyfikacji pojazdów na podstawie sygnatur uzyskanych z pojedynczej pętli indukcyjnej, wykorzystując cechy widmowe uzyskane dzięki transformacji Fouriera. Z kolei w badaniu [8] zaproponowano podwójną pętlę magnetyczną, która zastępuje funkcjonalność dwóch pojedynczych pętli, oferując poprawę funkcjonalności i cech w porównaniu do konwencjonalnych rozwiązań. Problematyka klasyfikacji pojazdów przy użyciu pojedynczej pętli indukcyjnej została również podjęta w pracy [38], gdzie analizowano znormalizowany profil magnetyczny pod względem amplitudy i czasu trwania. W badaniach [69] analizowano zastosowanie wąskiej pętli indukcyjnej do wykrywania osi pojazdów, co mogłoby znacząco poprawić dokładność stosowanych obecnie algorytmów klasyfikacji.

Ponadto, w pracy [66] wykazano, że zastosowanie pojedynczej pętli indukcyjnej w obszarach, gdzie tworzą się kolumny pojazdów, takich jak skrzyżowania, umożliwia identyfikację długich pojazdów, takich jak ciężarówki, na podstawie czasów zajętości detektora. W badaniu [76] przedstawiono algorytm, który wykorzystuje pojedynczą pętlę indukcyjną, oraz radialne sieci neuronowe do identyfikacji pojazdów ciężarowych.

Oprócz pętli indukcyjnych, do klasyfikacji pojazdów testowane są również inne typy czujników. Praca [65] zaproponowała zastosowanie punktowego czujnika magnetycznego oraz algorytmu umożliwiającego klasyfikację pojazdów do dwóch kategorii. Skuteczność tej metody była przedmiotem badań opisanych w pracy [63], gdzie również analizowano sygnały rejestrowane przez punktowy czujnik magnetyczny.

Jednym z kluczowych elementów systemów WIM są czujniki wagowe. Praca [13] szczegółowo omawia budowę oraz właściwości eksploatacyjne najczęściej stosowanych czujników wagowych, takich jak kwarcowe, polimerowe, pojemnościowe oraz płytowe. Zwrócono również tam uwagę na stopniowe wypieranie starszych technologii, takich jak czujniki płytowe i polimerowe, przez czujniki kwarcowe, które oferują lepsze właściwości metrologiczne. Wyniki pomiarów mogą jednak być również zależne od czynników środowiskowych, takich jak temperatura nawierzchni oraz prędkość pojazdu, co było przedmiotem analizy w pracy [37]. Aby zminimalizować wpływ zmian temperatury na wyniki ważenia w systemach z czujnikami polimerowymi, w pracy [14] zaproponowano zastosowanie algorytmów kompensujących, takich jak korekcja temperaturowa lub autokalibracja, czujniki kwarcowe okazały się mniej podatne na zmiany temperatury nawierzchni.

2. Opis systemów WIM

Rozwój systemów WIM napotkał również na wyzwania związane z dynamiką pojazdów oraz wpływem warunków zewnętrznych na dokładność pomiarów. W artykule [44] przedstawiono, że zastosowanie sztucznych sieci neuronowych w systemach WIM pozwala na identyfikację powtarzalnych zależności w dynamice osi pojazdów oraz wyeliminowanie zakłóceń, co jest trudne do osiągnięcia przy użyciu konwencjonalnych algorytmów. Sieci neuronowe mają zdolność adaptacji do zmieniających się warunków, co pozwala na lepsze radzenie sobie z zakłóceniami wynikającymi z profilu drogi, charakterystyką ruchu czy awariami czujników.

Kolejne prace koncentrują się na metodach poprawy dokładności pomiarów w systemach WIM. W artykule [10] autorzy opisują projekt TOP TRIAL, który skupił się na opracowaniu metod projektowania pól czujników WIM oraz algorytmów do oceny danych z pomiaru dynamicznego obciążenia osi. Opracowane w ramach tego projektu metody minimalizacji błędów opierają się na deterministycznych oraz stochastycznych podejściach do estymowania masy całkowitej pojazdu oraz modelowania drgań osi. W artykule zaprezentowano także symulacyjne i numeryczne metody obliczania i projektowania pól czujników WIM, które pozwalają na redukcję błędów związanych z dynamiką ruchu.

W kontekście optycznych systemów WIM, Janota, Šimák i Hrbček (2017) opisali rozwój nowego systemu WIM opartego na czujnikach optycznych w ramach projektu OPTIWIM. Celem tego projektu było opracowanie nowego systemu pomiarowego, który będzie bardziej odporny na zmienne warunki środowiskowe i będzie charakteryzował się większą dokładnością pomiarów. Praca ta opisuje różne optyczne metody pomiarowe, które były rozważane przez zespół badawczy oraz wyniki wstępnych testów nowego systemu [49].

Ostatnie lata przyniosły wzrost zainteresowania czujnikami światłowodowymi, które znajdują coraz szersze zastosowanie w systemach WIM. Przegląd najnowszych rozwiązań w tej dziedzinie został przedstawiony w pracy [29], gdzie omówiono zastosowania czujników światłowodowych w monitorowaniu stanu nawierzchni. W badaniach opisanych w pracy [49] przedstawiono wyniki wstępnych testów nowego systemu WIM opartego na czujnikach optycznych, gdzie rozważano różne optyczne metody pomiarowe, choć autorzy nie zdecydowali o wyborze ostatecznego rozwiązania. Innym podejściem, opisanym w pracy [50], jest zastosowanie licznych punktowych czujników rozmieszczonych w systemie, co pozwala na szczegółową analizę obciążeń pojazdów.

Dokładność systemów WIM zależy nie tylko od rodzaju zastosowanych czujników, ale również od jakości ich montażu oraz stanu nawierzchni drogi. W literaturze zaproponowano szereg metod, które mają na celu zmniejszenie błędów pomiarowych w systemach WIM. W pracy [59] omówiono różne algorytmy przetwarzania sygnałów z czujników piezoelektrycznych, takie

2.1. Przegląd powiązanych prac


jak algorytm wartości maksymalnej, pole powierzchni pod wykresem sygnału oraz ponowne próbkowanie. Zwrócono jednak uwagę, że algorytmy te nie rozwiązują wszystkich problemów, na przykład wpływu wiatru na wyniki pomiarów.

Alternatywnym rozwiązaniem są systemy WIM z wieloma czujnikami (MS-WIM), które umożliwiają wielokrotne pomiary obciążenia każdej osi pojazdu, co zwiększa dokładność pomiarów. W pracy [40] omówiono różne algorytmy, które mogą zmniejszać błędy wynikające z dynamiki ruchu oraz powtarzalności przestrzennej dynamiki osi. Przykładem prostego algorytmu jest estymator wartości oczekiwanej (średnia arytmetyczna), który oblicza średnią z wyników pomiarów chwilowej wartości nacisku na kolejnych czujnikach. Bardziej zaawansowane algorytmy wymagają modelowania dynamicznej siły oddziałującej na czujniki, gdzie siła ta jest sumą nacisku statycznego i dynamicznych składowych przedstawianych jako funkcje harmoniczne [22]. Aby zapewnić efektywność tych algorytmów, zwykle przyjmuje się jedną lub dwie składowe dynamiczne, które uwzględniają drgania pionowe masy resorowanej oraz nieresorowanej [40]. W bardziej zaawansowanych systemach stosuje się także algorytmy takie jak estymator największej wiarygodności (ML), nieliniowy estymator najmniejszych kwadratów (NLS), zmodyfikowany nieliniowy estymator najmniejszych kwadratów (MNLS) oraz nieliniowy filtr Kalmana [85], co pozwala na bardziej precyzyjne przetwarzanie danych z systemów WIM.

Sieci neuronowe stają się coraz bardziej popularnym narzędziem w systemach WIM, ze względu na ich zdolność do identyfikacji wzorców w danych oraz adaptacji do zmieniających się warunków. Przykład zastosowania sieci neuronowych w systemach WIM opisano w pracy [44], gdzie zwrócono uwagę na ich zdolność do identyfikowania powtarzalnych zależności w dynamice osi pojazdów. W pracy [50] wykorzystano sieć neuronową propagacji wstecznej (BPNN-i) do identyfikacji idealnych próbek sygnałów z czujników obciążenia, które znajdują się najbliżej obszaru styku opony z nawierzchnią. Te próbki zostały następnie wykorzystane do przewidywania całkowitej masy pojazdu za pomocą innej sieci neuronowej propagacji wstecznej (BPNN-e). Mimo to, głównym wyzwaniem związanym z zastosowaniem sieci neuronowych w systemach WIM jest konieczność zgromadzenia dużych zbiorów danych uczących i testujących, co może być trudne do zrealizowania w warunkach rzeczywistych [40].

Główne kierunki badawcze, przedstawione w literaturze dotyczącej systemów ważenia pojazdów w ruchu (WIM), obejmują zagadnienia takie jak optymalizacja procesów, redukcja złożoności obliczeniowej, ekstrakcja cech, a także wykorzystanie metod uczenia maszynowego i sztucznej inteligencji. Tematy te zostały zidentyfikowane jako kluczowe pod względem potencjału badawczego i dlatego znalazły się w zakresie niniejszej pracy.

2. Opis systemów WIM



Rysunek 2.2. Obszar pomiarowy, punkt pomiarowy i pole pomiarowe systemu WIM.
Źródło: materiały Komitetu architektury systemów ITS [46]

2.2. Ważenie pojazdów w ruchu

2.2.1. Budowa stacji ważenia pojazdów w ruchu

Stacje ważenia pojazdów w ruchu (WIM) to złożone systemy, które wykorzystują zaawansowaną technologię do mierzenia i analizowania parametrów pojazdów przejeżdżających przez określone punkty pomiarowe – patrz rys. 2.2.

Punkty pomiarowe przez które przejeżdża pojazd w trakcie przejazdu przez stację WIM [46]:

Obszar pomiarowy

Obszar pomiarowy to specjalnie przygotowany odcinek drogi, który spełnia szereg wymagań dotyczących sztywności, równości powierzchni oraz precyzji geometrycznej. Te właściwości są niezbędne do zapewnienia wysokiej dokładności pomiarów. Obszar ten zawiera zarówno punkt pomiarowy, jak i przyległe odcinki drogi, które muszą być odpowiednio zintegrowane z systemem pomiarowym, aby nie wpływały negatywnie na wyniki pomiarów.

Punkt pomiarowy

Punkt pomiarowy to lokalizacja na drodze, gdzie zainstalowane są sensory i inne urządzenia pomiarowe. W zależności od potrzeb i specyfikacji stacji WIM, może on zawierać różne kombinacje sensorów, takich jak czujniki pętlowe, piezoelektryczne, wagowe, oraz kamery do identyfikacji pojazdów i rejestracji tablic rejestracyjnych. W punkcie tym dokonuje się pomiaru wielu parametrów pojazdów, w tym masy, prędkości, rozstawu osi oraz wykonuje klasyfikację pojazdu.

Pole pomiarowe

Pole pomiarowe to konkretna lokalizacja w obrębie punktu pomiarowego, gdzie znajdują się czujniki i urządzenia pomiarowe. To właśnie w tym miejscu dokonywane są bezpośrednie pomiary charakterystyk przejeżdżających pojazdów. Konfiguracja tego pola zależy od rodzaju zainstalowanych sensorów oraz specyficznych wymagań dla danego typu pomiarów.

2.2.2. Rodzaje stacji ważenia pojazdów w ruchu

Stacje ważenia pojazdów w ruchu (WIM) są klasyfikowane na podstawie ich zastosowania oraz specyficznych funkcji technologicznych. W praktyce często są dzielone na trzy główne kategorie [20, 28, 46, 79]:

- **Systemy statystyczne (HS-WIM-S)** – systemy te służą do zbierania danych dotyczących ruchu pojazdów, takich jak całkowita masa, liczba osi, prędkość oraz rozkład masy na osie. Informacje te są kluczowe dla zarządzania infrastrukturą drogową, planowania działań konserwacyjnych oraz modernizacyjnych. Systemy te monitorują obciążenia infrastruktury w sposób ciągły, dostarczając dane niezbędne do analiz i raportów na potrzeby planistyczne.
- **Systemy preselekcyjne (HS-WIM-P)** – systemy te mają na celu wstępną selekcję pojazdów podejrzanych o przekroczenie dopuszczalnych norm wagowych. Pojazdy identyfikowane jako przeciążone są kierowane na stanowiska do dokładniejszego ważenia na legalizowanych wagach. Jeśli przeciążenie zostanie potwierdzone, rozpoczyna się procedura administracyjna. Systemy te są kluczowe w redukcji liczby przeciążonych pojazdów na drogach, co przekłada się na zmniejszenie uszkodzeń nawierzchni i poprawę bezpieczeństwa ruchu.
- **Systemy administracyjne (HS-WIM-E)** – zaawansowane technologicznie systemy, które

2. Opis systemów WIM

umożliwiają legalizowane pomiary mas pojazdów. Dane z tych systemów mogą być podstawą do wszczynania postępowań administracyjnych bez konieczności zatrzymywania pojazdów. Choć w Polsce obecnie brak przepisów pozwalających na certyfikację takich systemów, ich wprowadzenie jest oczekiwane ze względu na rosnącą potrzebę bardziej efektywnej kontroli przeciążonych pojazdów.

Systemów WIM według organizacji danych pomiarowych

Systemy WIM dodatkowo w praktyce często są dzielone ze względu na sposób przechowywania oraz dostęp do danych pomiarowych [94]:

- **Systemy lokalne** – dane są rejestrowane i przechowywane na lokalnym komputerze w punkcie ważenia. Pozwala to na szybkie przetwarzanie i analizę danych na miejscu, co jest szczególnie istotne, gdy konieczna jest natychmiastowa reakcja na wyniki pomiarów.
- **Systemy serwerowe** – dane z wielu stacji pomiarowych są gromadzone centralnie, co umożliwia scentralizowane zarządzanie i analizę. W przypadku braku łączności dane są zapisywane lokalnie, a następnie przesyłane do centralnego serwera po przywróceniu połączenia.

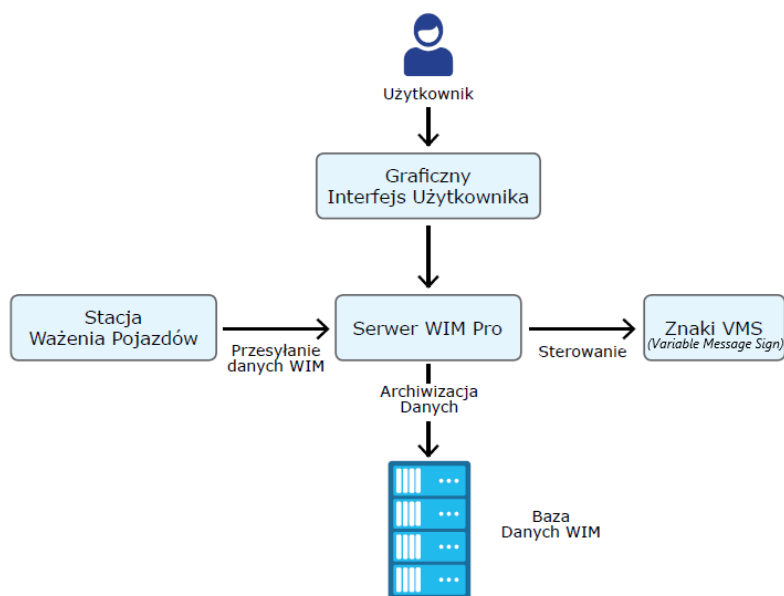
Funkcjonowanie systemu WIM

Systemy WIM są efektywnym narzędziem do selekcji pojazdów przeciążonych oraz egzekwowania przepisów dotyczących maksymalnej masy pojazdów. Tradycyjne wagi stacjonarne zostały zastąpione przez zintegrowane czujniki umieszczone w jezdni, co pozwala na automatyczny pomiar masy pojazdów bez konieczności ich zatrzymywania. Systemy te działają efektywnie nawet przy wysokich prędkościach, co eliminuje ryzyko zakłóceń w ruchu drogowym.

Pomiar masy pojazdu odbywa się podczas jego przejazdu przez obszar wyposażony w pętle indukcyjne i czujniki wagowe, które rejestrują takie parametry jak całkowita masa pojazdu, nacisk na poszczególne osie, liczba osi oraz wymiary pojazdu. Zebrane dane są przetwarzane w czasie rzeczywistym przez komputer wagowy i przesyłane do aplikacji zarządzającej, która umożliwia kompleksową analizę i zarządzanie danymi.

Dzięki integracji z innymi systemami zarządzania ruchem, możliwe jest skierowanie wybranych pojazdów do dodatkowego pomiaru na wagach stacjonarnych, co pozwala na potwierdzenie wyników i podjęcie działań administracyjnych w przypadku stwierdzenia naruszeń – patrz rys. 2.3.

2.3. Przykładowa aplikacja agregująca dane



Rysunek 2.3. Schemat działania preselekcyjnego systemu WIM. Źródło: materiały firmy APM PRO

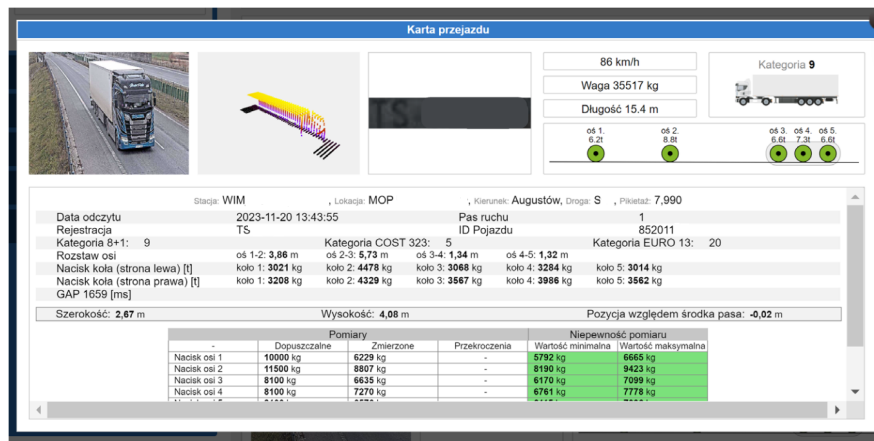
Przykładowo, przez stację ważenia pojazdów ruchu może dziennie przejeżdżać około 8000 pojazdów, z czego około 250 jest przeciążonych (dane ze stacji WIM zlokalizowanej na drodze wojewódzkiej z dnia 29.04.2024). Aktualnie możliwości kontroli w systemie preselekcyjnym obejmują maksymalnie 10 pojazdów dziennie, co podkreśla potrzebę wdrażania bardziej zaawansowanych rozwiązań.

2.3. Przykładowa aplikacja agregująca dane

Jednym z przykładów aplikacji agregujących dane z systemu ważenia pojazdów w ruchu jest aplikacja WIM PRO 3, opracowana przez firmę APM PRO [6] – patrz rys. 2.4. Na rynku dostępne są również inne rozwiązania, takie jak aplikacje firm Neurocar [78], CrossTraffic (CrossWIM) [27] oraz Viver (Viver WIM) [21] oraz wiele innych.

Do systemu trafiają zintegrowane rekordy z przejazdów pojazdów przez stacje ważenia. Dane te obejmują takie informacje jak: rozstaw osi, zdjęcia tablic rejestracyjnych, zdjęcia poglądowe, liczba osi, masa całkowita pojazdu, masa poszczególnych osi, prędkość przejazdu, długość pojazdu, godzina przejazdu, pas ruchu, po którym poruszał się pojazd, wizualizację układu osi (z rozróżnieniem na osie pojedyncze i grupowe), klasyfikację według różnych standardów, odległość od poprzedzającego pojazdu, wymiary pojazdu (wysokość i szerokość),

2. Opis systemów WIM



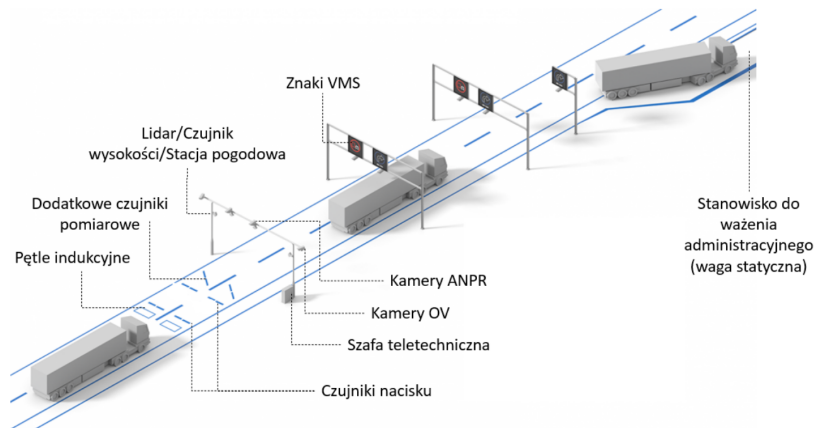
Rysunek 2.4. Przykładowa aplikacja: WIM PRO 3. Źródło: materiały firmy APM PRO

naciski poszczególnych kół oraz pozycję pojazdu względem środka pasa. Integracja systemu z dynamicznymi znakami VMS (ang. *Variable Message Signs*) umożliwia efektywne kierowanie pojazdów na wyznaczone miejsca parkingowe, gdzie mogą zostać poddane dalszym kontrolom. System może pracować w trybie automatycznym lub półautomatycznym, co pozwala na selektywne kontrole pojazdów określonego typu. Do najbardziej zaawansowanych funkcji systemu należy detekcja podwójnych opon oraz analiza toru przejazdu, co umożliwia bardziej precyzyjne monitorowanie.

2.3.1. Integracja z rządowymi bazami danych

Aplikacje takie jak WIM PRO 3 umożliwiają integrację i przesyłanie danych w wymaganym formacie do rządowych baz danych, co w efekcie może prowadzić do automatycznego wystawiania mandatów za naruszenia przepisów dotyczących dopuszczalnej masy pojazdów. Funkcjonalność ta znacząco usprawnia działania służb odpowiedzialnych za egzekwowanie przepisów ruchu drogowego, eliminując potrzebę ręcznego przetwarzania danych i przyspieszając proces egzekwowania kar. W pełni zautomatyzowany tryb działania systemu eliminuje konieczność stałego zaangażowania służb, jednocześnie zapewniając ciągłe monitorowanie ruchu drogowego bez negatywnego wpływu na jego płynność. Dzięki automatyzacji procesów monitorowania i egzekwowania przepisów, system ten stanowi zaawansowane i skuteczne narzędzie do ochrony infrastruktury drogowej.

2.4. Wdrożenie systemów HS-WIM-E: znaczenie i korzyści



Rysunek 2.5. System pomiarowy stacji WIM na przykładzie wagi preselekcyjnej.
Źródło: materiały Komitetu architektury systemów ITS [46]

2.4. Wdrożenie systemów HS-WIM-E: znaczenie i korzyści

Wprowadzenie zaawansowanych systemów HS-WIM-E (ang. *High-Speed Weigh-In-Motion-Enforcement*) jest kluczowe dla zwiększenia efektywności i skuteczności kontroli pojazdów przeciążonych. Systemy te przyczyniają się do ochrony infrastruktury drogowej poprzez precyzyjne monitorowanie masy pojazdów, co pozwala na szybsze i bardziej dokładne identyfikowanie pojazdów przekraczających dopuszczalne normy obciążenia. Automatyzacja procesu egzekwowania przepisów zmniejsza obciążenie pracą inspektorów, pozwalając im skupić się na bardziej złożonych zadaniach, jednocześnie zwiększając bezpieczeństwo na drogach – patrz rys. 2.5.

2.5. Rodzaje systemów ważenia pojazdów


W Polsce najczęściej stosowane są systemy preselekcyjne, które można podzielić na dwa główne typy: wagi statyczne i dynamiczne [97] – patrz rys. 2.6. Dokładny opis rodzajów i systemów ważenia pojazdów w ruchu znajduje się w [18].

2.5.1. Wagi statyczne

Wagi statyczne, stosowane w zatokach Inspekcji Transportu Drogowego (ITD), wymagają zatrzymania pojazdu w celu dokonania pomiaru. Główną zaletą wag statycznych jest ich wysoka precyzja, co czyni je idealnymi do potwierdzania lub wykluczania przekroczenia

2. Opis systemów WIM

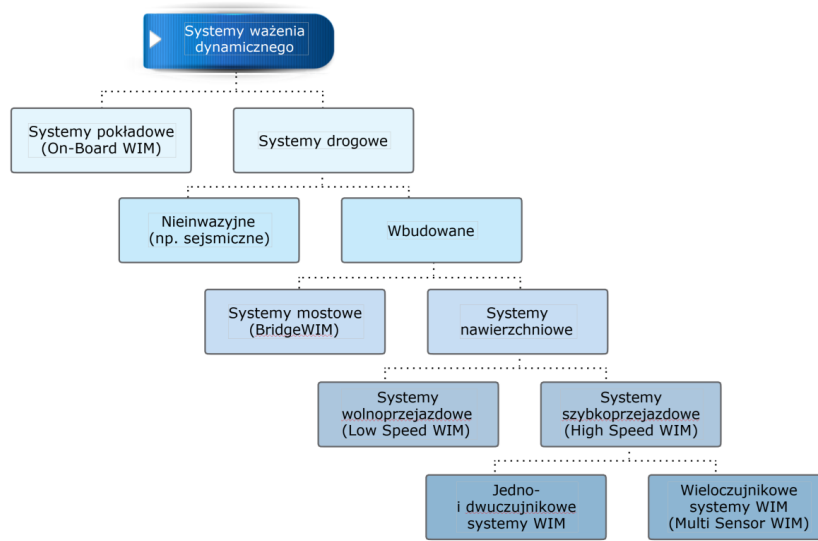
dopuszczalnej masy pojazdu. Wadą jest czasochłonność i konieczność posiadania odpowiedniej infrastruktury, co może ograniczać ich zastosowanie. Wagi te są często wykorzystywane po wstępnym preselekcyjnym ważeniu przeprowadzonym przez systemy dynamiczne.



Rysunek 2.6. Podział systemów ważących pojazdy. Źródło: materiały firmy APM PRO

2.5.2. Wagi dynamiczne (WIM)

Wagi dynamiczne, znane również jako systemy WIM, umożliwiają ważenie pojazdów w ruchu, eliminując konieczność ich zatrzymywania. Dzięki ciągłemu i automatycznemu pomiarowi, systemy te pozwalają na kompleksową analizę wszystkich pojazdów, co jest kluczowe dla skutecznego zarządzania ruchem drogowym oraz ochrony infrastruktury. Systemy WIM można podzielić na różne podtypy, w zależności od miejsca instalacji i technologii (rys. 2.7):



Rysunek 2.7. Klasyfikacja systemów ważenia dynamicznego. Źródło: materiały firmy APM PRO

2.5. Rodzaje systemów ważenia pojazdów

Systemy pokładowe (On-Board WIM)

W systemach pokładowych czujniki są zintegrowane bezpośrednio z pojazdem, co umożliwia samoważenie w czasie rzeczywistym, zarówno podczas ruchu, jak i postoju. Jest to szczególnie przydatne w flotach komercyjnych, gdzie ciągłe monitorowanie obciążenia pojazdu może zapobiegać przeciążeniom oraz związanym z tym problemom technicznym i prawnym.

Systemy nieinwazyjne

Systemy nieinwazyjne, takie jak systemy sejsmiczne, mierzą drgania gruntu wywołane przez przejeżdżające pojazdy. Choć te systemy oferują niższą dokładność w porównaniu do tradycyjnych metod, są one użyteczne w miejscach, gdzie instalacja bardziej inwazyjnych technologii jest niepraktyczna lub zbyt kosztowna.

Systemy wbudowane (Bridge WIM i nawierzchniowe)

Systemy Bridge WIM monitorują odkształcenia konstrukcji mostów, umożliwiając dokładne pomiary nacisków osi pojazdów. Systemy te są kluczowe dla monitorowania stanu technicznego mostów. Z kolei systemy nawierzchniowe mogą być instalowane w drodze i dzielą się na Low-Speed WIM (do niskich prędkości) oraz High-Speed WIM (do wysokich prędkości), które umożliwiają ważenie pojazdów bez ich zatrzymywania, bezpośrednio na pasie ruchu.

Systemy wolno przejazdowe (Low-Speed WIM)

Systemy Low-Speed WIM są wykorzystywane do dokładnych pomiarów masy pojazdów przy ograniczeniu prędkości do ok. 10 km/h. Proces ważenia odbywa się na specjalnie przygotowanym stanowisku poza głównym pasem ruchu, co zapewnia precyzyjne warunki pomiarowe. Czujniki, trwale zamontowane w nawierzchni, rejestrują dane, umożliwiając szybkie i dokładne ważenie pojazdów. Jednakże, metoda ta wiąże się z koniecznością przekierowania pojazdów na stanowisko pomiarowe, co może prowadzić do dodatkowych kosztów związanych z instalacją i utrzymaniem systemu. W przypadku zmiany prędkości podczas ważenia konieczne jest powtórzenie pomiaru, co stanowi pewne ograniczenie tej technologii. Systemy Low-Speed WIM są często stosowane w punktach poboru opłat oraz jako wagi administracyjne, gdzie ich wysoka dokładność jest kluczowa dla zgodności z regulacjami prawnymi i normami obciążenia.

2. Opis systemów WIM

Systemy szybko przejazdowe (High-Speed WIM)

Systemy High-Speed WIM umożliwiają ważenie pojazdów w ruchu bez konieczności ich zatrzymywania. Czujniki pomiarowe są bezpośrednio zintegrowane z nawierzchnią drogi, co pozwala na automatyczne i ciągle monitorowanie pojazdów poruszających się z normalną prędkością. Technologia ta wykorzystuje średnią arytmetyczną wyników z kilku czujników, co zapewnia wiarygodne i dokładne pomiary masy i nacisku osi pojazdów.

High-Speed WIM znacząco zwiększa efektywność zarządzania ruchem drogowym, umożliwiając natychmiastowe gromadzenie danych o wszystkich przejeżdżających pojazdach. Dzięki zaawansowanym algorytmom przetwarzania danych oraz ciągłym postępom technologicznym, systemy te oferują coraz wyższą dokładność, co jest kluczowe dla ochrony infrastruktury drogowej i zapewnienia bezpieczeństwa na drogach. Systemy te eliminują potrzebę budowy dodatkowych miejsc pomiarowych, co czyni je bardziej elastycznymi i łatwiejszymi w integracji z istniejącą infrastrukturą drogową.

Systemy wieloczujnikowe (Multi-Sensor WIM)

Systemy Multi-Sensor WIM wykorzystują wiele czujników, co poprawia dokładność pomiarów przy wysokich prędkościach. Dzięki większej liczbie czujników możliwe jest zastosowanie zaawansowanych algorytmów, które minimalizują wpływ prędkości pojazdu na dokładność pomiarów. Chociaż systemy te są droższe, są szczególnie efektywne w miejscach o dużym natężeniu ruchu.

2.6. Komponenty i technologie w systemach WIM

W zależności od typu stacji WIM, różnią się one wyposażeniem i zakresem funkcjonalności. W tabeli 2.1 przedstawiono kluczowe komponenty systemów WIM oraz ich zastosowanie w różnych typach stacji.

2.7. Czujniki detekcji pojazdów


Proces pomiaru w systemach WIM rozpoczyna się, gdy pojazd przejeżdża nad pętlą indukcyjną, która służy wykryciu jego obecności na drodze (rys. 2.8). Pętla indukcyjna jest kluczowym

2.7. Czujniki detekcji pojazdów

Tabela 2.1. Kluczowe komponenty systemów WIM w różnych typach stacji. Na podstawie [46]

Komponent	Opis	HS-WIM-S	HS-WIM-P	HS-WIM-E
Pętle indukcyjne	Zainstalowane w nawierzchni drogi, wykrywają obecność pojazdów oraz mierzą ich prędkość i kierunek ruchu.	Tak	Tak	Tak
Czujniki nacisku	Kluczowe dla pomiaru masy pojazdów i nacisków osi. Mogą być piezoelektryczne, kwarcowe lub tensometryczne, zależnie od wymagań pomiarowych.	Tak	Tak	Tak
Kamery ANPR/Poglądowe	Automatyczne rozpoznawanie tablic rejestracyjnych oraz monitoring wizyjny ruchu pojazdów, co umożliwia identyfikację pojazdów i zapewnia bezpieczeństwo na stacji.	Opcjonalnie	Tak	Tak
Czujnik wysokości	Mierzy wysokość pojazdów, co jest istotne dla określenia ich gabarytów i zgodności z normami drogowymi.	Nie	Tak	Tak
Lidar	Umożliwia dokładne skanowanie pojazdów i tworzenie ich trójwymiarowych modeli, co jest przydatne w precyzyjnej analizie ich wymiarów i kształtów.	Nie	Opcjonalnie	Tak
Stacja meteorologiczna	Mierzy warunki pogodowe, co pozwala na kalibrację i korektę pomiarów wagowych, zapewniając ich dokładność niezależnie od warunków atmosferycznych.	Nie	Opcjonalnie	Tak
Znaki o zmiennej treści (VMS)	Informują kierowców o wynikach ważenia i ewentualnych przekroczeniach dozwolonej masy oraz kierują na dodatkowe kontrole, jeśli to konieczne.	Nie	Opcjonalnie	Nie
Dodatkowe czujniki	Mogą obejmować różne technologie, takie jak skanery 3D, LiDAR lub inne precyzyjne urządzenia pomiarowe, dostosowane do specyficznych potrzeb stacji WIM.	Nie	Opcjonalnie	Tak

2. Opis systemów WIM



Rysunek 2.8. Wykrycie pojazdu przejeżdżającego przez pętlę indukcyjną. Źródło: materiały firmy APM PRO

elementem systemu WIM, umożliwiającym dokładne monitorowanie i rejestrowanie przejazdu pojazdów. W momencie detekcji, pętla indukcyjna generuje sygnał, który inicjuje dalsze procesy pomiarowe, takie jak odczyt prędkości, kierunku ruchu oraz identyfikacja pojazdu.

2.7.1. Rodzaje czujników w systemach WIM

W systemach WIM stosuje się różnorodne czujniki, z których każdy ma specyficzne zastosowanie oraz właściwości techniczne. Poniżej opisano najczęściej wykorzystywane typy czujników. Dokładny opis różnych czujników detekcji pojazdów znajduje się w [75].

Czujnik indukcyjny pętlowy

Czujnik indukcyjny pętlowy wykrywa zakłócenia magnetyczne spowodowane przez metalowe elementy pojazdu, które mijają czujnik. Zmiana impedancji pętli indukcyjnej, wynikająca z obecności pojazdu, pozwala na akwizycję profilu magnetycznego pojazdu. Dzięki wysokiej niezawodności i precyzji, czujniki te są powszechnie stosowane w systemach WIM.

Czujnik linkowy

Czujnik linkowy składa się ze stalowej linki zamocowanej z jednej strony oraz ruchomego styku elektrycznego z drugiej strony. Zwarcie styku następuje w momencie detekcji osi pojazdu. Czujniki te cechują się łatwością instalacji, ale wymagają częstej konserwacji, co czyni je

2.7. Czujniki detekcji pojazdów

bardziej odpowiednimi do krótkoterminowych instalacji testowych niż do długoterminowego monitorowania.

Czujnik taśmowy

Czujnik taśmowy składa się z dwóch elastycznych metalowych pasków umieszczonych w gumowej obudowie, między którymi znajduje się gaz obojętny. Przejazd pojazdu powoduje chwilowe zetknięcie się pasków, co zmienia stan wyjścia czujnika. Czujniki taśmowe są używane do precyzyjnego monitorowania osi pojazdów, oferując wysoką dokładność w różnych warunkach eksploatacyjnych.

Czujnik rezystancyjny

Czujnik rezystancyjny wykorzystuje elastyczny materiał o zmiennej rezystancji, która zmienia się pod wpływem obciążenia. Choć czujniki te są trudniejsze do zastosowania w ważeniu pojazdów z powodu nieliniowości zmiany rezystancji, są skuteczne w wykrywaniu osi przy niskich prędkościach, np. na bramkach poboru opłat. Charakteryzują się wysoką wytrzymałością i łatwością eksploatacji.

Przetwornik hydrauliczny

Przetwornik hydrauliczny składa się z cylindra wypełnionego nieściśliwą cieczą, taką jak olej, z kapilarą na jednym końcu. Pod wpływem nacisku na cylinder, płynny materiał przewodzący, taki jak rtęć, zwiera styki, generując sygnał. Mimo że przetworniki hydrauliczne oferują wysoką precyzję, ich trwałość może być ograniczona przy intensywnym użytkowaniu, co czyni je mniej odpowiednimi do długoterminowych zastosowań.

Czujniki pneumatyczne

Czujniki pneumatyczne działają podobnie jak przetworniki hydrauliczne, ale wykorzystują powietrze zamiast cieczy. Sygnał generowany jest przez styki elektryczne przymocowane do membrany lub manometru, który pobudza czujnik piezoelektryczny. Czujniki pneumatyczne są preferowane w środowiskach wymagających szybkiej reakcji, choć są mniej dokładne niż czujniki hydrauliczne.

Czujniki magnetyczne

Czujniki magnetyczne, podobnie jak pętle indukcyjne, reagują na zmiany pola magnetycznego Ziemi w obecności obiektów ferromagnetycznych. Są one łatwiejsze w instalacji i mniej ingerują w nawierzchnię drogi, jednak mogą być podatne na zakłócenia elektromagnetyczne oraz zmienne warunki atmosferyczne, co wpływa na ich dokładność.


Wirtualne pętle

Wirtualne pętle wykorzystują kamery do detekcji pojazdu, co inicjuje proces ważenia oraz skanowanie 3D. Przy odpowiednim umieszczeniu kamery możliwe jest także rozpoznanie liczby osi pojazdu. Ta technologia pozwala na monitorowanie pojazdów bez fizycznej ingerencji w nawierzchnię drogi, co jest szczególnie korzystne w obszarach miejskich, gdzie przestrzeń jest ograniczona, a instalacja tradycyjnych czujników może być problematyczna.

2.8. Czujniki do ważenia pojazdów w ruchu

Ważenie pojazdów w ruchu opiera się na estymacji nacisków statycznych na podstawie dynamicznych nacisków kół pojazdu na podłoże. Proces ten rozpoczyna się, gdy pojazd, po przejechaniu przez czujniki obecności, przemieszcza się nad czujnikami pomiarowymi nacisku (rys.2.9). Czujniki te precyzyjnie mierzą całkowitą masę pojazdu, rejestrując siłę wywieraną przez opony na nawierzchnię, a następnie przekształcając ją w proporcjonalny sygnał elektryczny. Dokładny opis różnych rodzajów czujników znajduje się w [19].

2.8. Czujniki do ważenia pojazdów w ruchu



Rysunek 2.9. Pomiar ciężaru przez wagę pomiarową. Źródło: materiały firmy APM PRO

2.8.1. Czujniki światłowodowe

Czujniki światłowodowe wykorzystują zjawisko zmiany propagacji fal świetlnych wewnątrz światłowodu pod wpływem siły zewnętrznej. Parametry fali świetlnej zmieniają się proporcjonalnie do przyłożonego obciążenia, co pozwala na precyzyjny pomiar nacisku. Czujniki te są wysoko cenione za swoją odporność na zakłócenia elektromagnetyczne i są idealne do zastosowań w trudnych warunkach środowiskowych.

2.8.2. Czujniki pojemnościowe

Czujniki pojemnościowe działają na zasadzie zmiany pojemności między dwiema przewodzącymi elektrodami, które są izolowane dielektrykiem. Pod wpływem nacisku elektrody zbliżają się do siebie, co zmienia pojemność czujnika, a ta zmiana jest mierzona przez układ elektroniczny. Mimo swojej dużej wytrzymałości mechanicznej, czujniki te są podatne na uszkodzenia mechaniczne i mogą być narażone na korozję, zwłaszcza w warunkach zimowych, gdzie stosuje się sól drogową.

2.8.3. Czujniki piezoelektryczne

Czujniki piezoelektryczne wykorzystują zjawisko piezoelektryczne, polegające na generowaniu ładunku elektrycznego pod wpływem nacisku. Zbudowane są zazwyczaj z piezoceramików w formie koncentrycznego przewodu lub płaskiej taśmy. Dzięki swojej niezawodności i precyzji,

2. Opis systemów WIM

czujniki te są szeroko stosowane w systemach ważenia pojazdów, szczególnie w aplikacjach dynamicznych, gdzie szybkość i dokładność pomiaru są kluczowe.

2.8.4. Czujniki kwarcowe

Czujniki kwarcowe, podobnie jak piezoelektryczne, działają na zasadzie zjawiska piezoelektrycznego, ale jako element pomiarowy wykorzystują kryształ kwarcu. Charakteryzują się doskonałymi właściwościami metrologicznymi, stabilnością parametrów, odpornością na zmiany temperatury oraz zakłócenia elektromagnetyczne. Mimo że są kosztowne i wymagają większej ingerencji w nawierzchnię drogi, ich niezawodność i precyzja sprawiają, że są szeroko stosowane w systemach WIM.


2.8.5. Czujniki tensometryczne

Czujniki tensometryczne mierzą zmiany rezystancji przewodnika lub półprzewodnika pod wpływem naprężeń. Zwykle są instalowane w formie platform podpartych na belkach, z których każda wyposażona jest w tensometry mierzące odkształcenie. Aby zminimalizować wpływ temperatury i zmaksymalizować czułość, stosuje się układ pełnego mostka z czterema tensometrami. Ze względu na swoją wysoką dokładność i niezawodność, czujniki tensometryczne są powszechnie stosowane w systemach ważenia pojazdów.

2.9. Komputer wagowy

Komputer wagowy jest centralnym elementem systemu akwizycji i przetwarzania sygnałów w systemach WIM (*Weigh-In-Motion*) – patrz rys. 2.10. To zaawansowane urządzenie wykorzystuje precyzyjne przetworniki analogowo-cyfrowe oraz programowalne układy FPGA (*Field-Programmable Gate Array*), co zapewnia efektywne przetwarzanie i integrację sygnałów pochodzących z różnorodnych czujników, takich jak tensometryczne czujniki obciążenia, pętle indukcyjne oraz piezoelektryczne czujniki polimerowe. Opis zastosowań i wymagań stawianych komputerom wagowy znajduje się w [35].

2.9. Komputer wagowy



Rysunek 2.10. Przetwarzanie danych w ramach systemu iWIM. Źródło: z artykułu [54]


System ten, oparty na dedykowanym komputerze przemysłowym, umożliwia również integrację sygnałów z czujników meteorologicznych oraz kamer cyfrowych, co pozwala na kompleksowe monitorowanie i analizę różnych parametrów środowiskowych wpływających na dokładność pomiarów.

2.9.1. Częstotliwość próbkowania i przetwarzanie sygnałów

W celu zapewnienia wysokiej precyzji pomiarów, dla sygnałów z czujników obciążenia (tensometrów) oraz czujników piezoelektrycznych stosuje się częstotliwość próbkowania wynoszącą 31 250 Hz. Zaś dla sygnałów z pętli indukcyjnych częstotliwość ta wynosi 3 125 Hz. Wartości te pozwalają na dokładne rejestrowanie dynamicznych zmian obciążenia, które występują podczas przejazdu pojazdu.

Przykłady zarejestrowanych przebiegów sygnałów w oknie czasowym dla pojedynczego przejazdu pojazdu pięcioosiowego przedstawiono na Rysunku 2.11.

2. Opis systemów WIM



Rysunek 2.11. Przebiegi sygnałów we wspólnym oknie czasowym dla pojedynczego przejazdu pojazdu pięciosiowego. Źródło: z artykułu [54]

2.9.2. Integracja i analiza sygnałów

Na rysunku 2.11 przedstawiono przebiegi sygnałów zarejestrowane za pomocą:

- czterech tensometrycznych czujników obciążenia, umieszczonych parami w dwóch liniach prostopadłych do osi drogi,
- dwóch czujników piezoelektrycznych umieszczonych pod kątem 45° do osi drogi, rejestrujących sygnały dla lewego i prawego koła pojazdu,
- dwóch pętli indukcyjnych, które odczytują sygnaturę magnetyczną pojazdu.

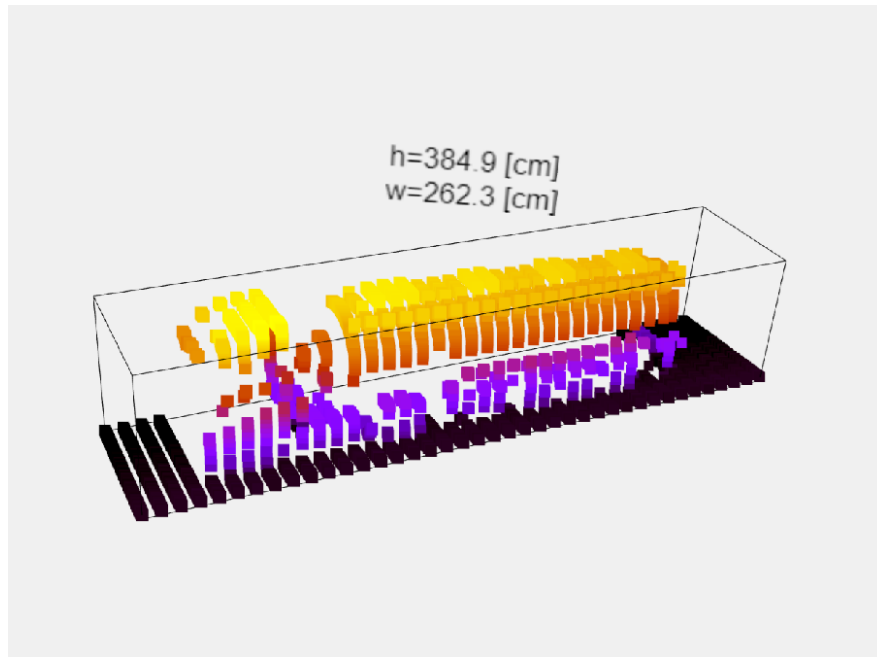
Takie rozmieszczenie czujników pozwala na uzyskanie szczegółowych i precyzyjnych danych dotyczących parametrów przejeżdżającego pojazdu, co jest niezbędne do dokładnej analizy obciążenia oraz oceny stanu technicznego pojazdu.

System integruje różnorodne sygnały z czujników, co umożliwia kompleksową ocenę dynamicznych obciążeń i zachowań pojazdów w ruchu. Przetworzone dane są wykorzystywane do analizy stanu infrastruktury drogowej, monitorowania przestrzegania przepisów dotyczących masy pojazdów oraz optymalizacji zarządzania ruchem drogowym.

2.10. Inne źródła danych

W systemach ważenia pojazdów w ruchu, oprócz czujników nacisku, wykorzystuje się również różnorodne dodatkowe źródła danych, takie jak czujniki temperatury, kierunku i prędkości wiatru, kamery oraz skanery 3D. Te dodatkowe źródła danych pozwalają na uzyskanie

2.10. Inne źródła danych



Rysunek 2.12. Skan 3D z wyznaczonymi wymiarami pojazdu. Źródło: materiały firmy APM PRO

kompleksowego obrazu warunków środowiskowych oraz parametrów pojazdów. Opis innych źródeł danych znajduje się w [34].


2.10.1. Skaner 3D - LiDAR

Skaner LiDAR wykorzystuje technologię teledetekcji, polegającą na emisji intensywnych impulsów światła laserowego w kierunku pojazdu. Światło laserowe odbija się od powierzchni pojazdu, co umożliwia precyzyjne pomiary odległości, prędkości, kształtu oraz wymiarów pojazdu. LiDAR dostarcza wysokiej rozdzielczości obrazów 3D, które są kluczowe dla dokładnej analizy technicznej pojazdów poruszających się po drogach. Przykładowy skan przedstawiono na rys. 2.12.

2.10.2. Kamery poglądowe i ANPR

W systemach WIM istotną rolę odgrywają również kamery poglądowe oraz kamery ANPR, które są zamontowane nad pasami ruchu. Kamera poglądowa rejestruje obraz badanego pojazdu, a następnie przekazuje uzyskane zdjęcie wraz z innymi zebranymi danymi do systemu. Dzięki temu możliwe jest uzyskanie wizualnej dokumentacji pojazdu, co stanowi integralną

2. Opis systemów WIM



Rysunek 2.13. Kamera poglądowa wykonuje zdjęcie boku pojazdu z widocznymi osiami. Źródło: materiały firmy APM PRO

część monitorowania ruchu. Schemat działania kamery poglądowej na stacji WIM przedstawiono na rys. 2.13.

Kamera ANPR (Automatic Number Plate Recognition) została zaprojektowana do precyzyjnej identyfikacji oraz rejestrowania obrazów tablic rejestracyjnych pojazdów. Technologia ta pozwala na uzyskanie ostrych i czytelnych zdjęć numerów rejestracyjnych, co umożliwia jednoznaczną identyfikację pojazdów. Zakres działania kamery powinien obejmować przynajmniej jeden pas ruchu, aby zapewnić pełną efektywność systemu. Ponadto urządzenie może być skonfigurowane za pomocą połączenia Ethernet, co ułatwia integrację i zarządzanie danymi. Schemat działania kamery ANPR na stacji WIM przedstawiono na rys. 2.14.

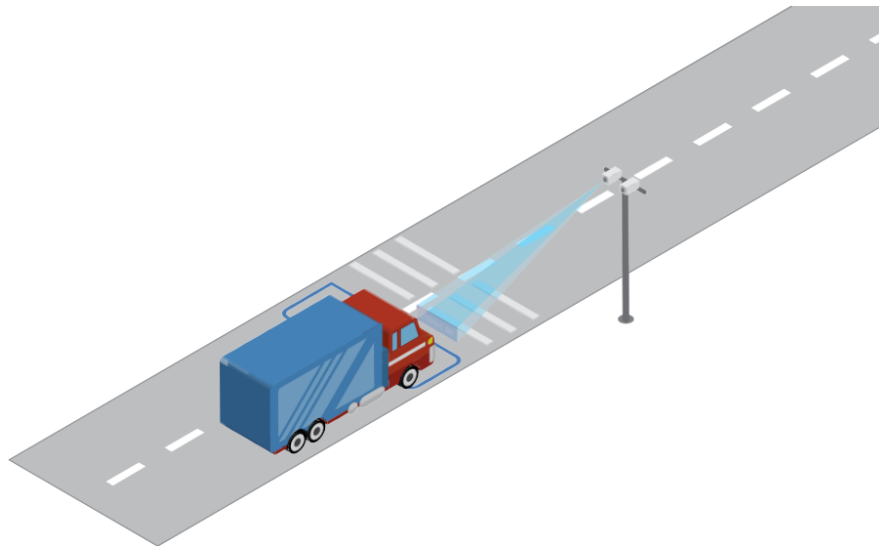
2.11. Sygnały otrzymywane z stacji ważenia pojazdów w ruchu

W systemach WIM (*Weigh-In-Motion*) dane nieprzetworzone, z którymi pracujemy, obejmują przede wszystkim dane z pętli indukcyjnych oraz czujników wagowych. Dane pochodzące z innych elementów systemu, takich jak stacje meteorologiczne, kamery czy skanery 3D, są już przetworzone przed ich udostępnieniem do dalszej analizy.

W ramach niniejszych badań podjęto próby wykorzystania tych przetworzonych danych do różnych celów, takich jak:

- stworzenie klasyfikatora na podstawie obrazów z kamer,
- opracowanie silnika OCR (*Optical Character Recognition*) do odczytu tablic rejestracyjnych,

2.12. Algorytmy służące do przetwarzania sygnałów z czujników WIM



Rysunek 2.14. Kamera ANPR wykonuje zdjęcie tablicy rejestracyjnej pojazdu. Źródło: materiały firmy APM PRO

- predykcja stanu nawierzchni na podstawie danych ze stacji meteorologicznych.

Jednakże badania te są na wczesnym etapie i nie zostały szczegółowo opisane w niniejszej pracy.


W niniejszej pracy skupiono się na sygnałach, które stanowią podstawę budowy stacji WIM, czyli odczytach z pętli indukcyjnych oraz wag. Reszta elementów systemu, takich jak kamery czy stacje meteo, jest opcjonalna i nie musi wchodzić w skład systemu ważenia pojazdów w ruchu. Badanie koncentruje się na najprostszym przypadku – stacji ważenia pojazdów w ruchu, która zbiera informacje o przejeżdżających pojazdach do celów statystycznych.

Dzięki komputerowi wagowemu iWIM, sygnały z pętli indukcyjnych i czujników wagowych zostały zintegrowane w jednym oknie czasowym, co umożliwia kompleksową analizę danych o pojazdach w ruchu. Zintegrowane sygnały przedstawiono na rys. 2.15.

2.12. Algorytmy służące do przetwarzania sygnałów z czujników WIM

W systemach Ważenia w Ruchu (WIM) z czujnikami piezoelektrycznymi kluczowe jest przetwarzanie sygnałów w celu precyzyjnego oszacowania wagi pojazdów. Artykuł autorstwa Taek M. Kwon opisuje zaawansowane algorytmy przetwarzania sygnałów stosowane w takich systemach [59].

2. Opis systemów WIM



Rysunek 2.15. Przykłady zarejestrowanych przebiegów zintegrowanych sygnałów w oknie czasowym dla pojedynczego przejazdu pojazdu 5-osowego. Źródło: z artykułu [54]

2.12.1. Metoda szczytowego napięcia

Najprostszą metodą jest wykorzystanie szczytowego napięcia sygnału do obliczenia wagi pojazdu. Szczytowe napięcie jest bezpośrednio proporcjonalne do wagi pojazdu, jednak metoda ta jest wrażliwa na zmiany ciśnienia w oponach, co może wpływać na dokładność. Metoda ta nie wymaga pomiaru prędkości pojazdu, co czyni ją użyteczną w aplikacjach, gdzie dokładność nie jest kluczowa.

$$W = \alpha \cdot \max(x_i), \quad (2.1)$$

gdzie W to waga pojazdu, α to współczynnik kalibracyjny, a x_i to zmierzony sygnał.

2.12.2. Metoda powierzchni pod sygnałem

Bardziej zaawansowana metoda polega na obliczaniu wagi na podstawie całkowitej powierzchni pod sygnałem oraz prędkości pojazdu. Dokładność tej metody zależy od precyzyjnego pomiaru prędkości, dlatego często stosuje się dwa rzędy czujników. Powierzchnia pod sygnałem jest następnie przekształcana na wagę przy użyciu odpowiednich współczynników kalibracyjnych.

$$W = \alpha \cdot \frac{S}{L} \cdot \int_{t_1}^{t_2} (x(t) - b(t)) dt \quad (2.2)$$

2.13. Algorytmy służące do przetwarzania sygnałów z czujników indukcyjnych pętlowych

gdzie S to prędkość pojazdu, L to szerokość czujnika, $x(t)$ to zmierzony sygnał, a $b(t)$ to poziom zerowy sygnału.

2.12.3. Metoda re-samplingu powierzchni

Metoda re-samplingu powierzchni jest udoskonaloną wersją poprzedniej metody, która dzieli sygnał na mniejsze próbki, eliminując wpływ szerokości czujnika na dokładność pomiaru. Ta metoda nie wymaga kalibracji, ponieważ wykorzystuje fabryczne parametry czułości czujników piezoelektrycznych. Dzięki temu możliwe jest uzyskanie bardzo precyzyjnych wyników, nawet w zmiennych warunkach.

$$W = \frac{1}{G \cdot \gamma} \cdot \sum_j x_j \quad (2.3)$$

gdzie G to wzmacnienie wzmacniacza ładunkowego, γ to czułość czujnika, a x_j to zmierzony sygnał dla próbki j .

2.13. Algorytmy służące do przetwarzania sygnałów z czujników indukcyjnych pętlowych

W systemach Ważenia w Ruchu (WIM) z wykorzystaniem pętli indukcyjnych, kluczową rolę odgrywają algorytmy detekcji pojazdów. Poniżej przedstawiono kilka algorytmów stosowanych w takich systemach.

2.13.1. Algorytm prostej detekcji

Ten algorytm wykrywa pojazd, gdy zmiana indukcyjności przekracza ustalony próg. Detektor monitoruje sygnał i wykrywa pojazd, gdy poziom sygnału spada poniżej (lub wzrasta powyżej) określonego poziomu.

$$\text{Wykrycie pojazdu, gdy } |L(t) - L_0| > \text{próg} \quad (2.4)$$

gdzie $L(t)$ to aktualna indukcyjność, a L_0 to indukcyjność w stanie bez pojazdu.

2.13.2. Algorytm detekcji szczytów

Wartości szczytowe sygnału są wykorzystywane do detekcji i klasyfikacji pojazdów. Gdy pojazd przejeżdża nad pętlą, indukcyjność zmienia się, co powoduje zmiany w sygnale. Detekcja szczytów polega na identyfikacji maksymalnych wartości w sygnale.

$$\text{Szczyt} = \max(x(t)) \quad (2.5)$$

gdzie $x(t)$ to sygnał wyjściowy z pętli indukcyjnej.

2.13.3. Algorytm filtracji sygnału

Algorytmy filtracji są używane do eliminacji szumów i zakłóceń. Najczęściej stosowane filtry to filtry dolnoprzepustowe, które przepuszczają sygnały o niskich częstotliwościach, eliminując wysokoczęstotliwościowe zakłócenia.

$$y(t) = \int_{-\infty}^{\infty} x(\tau)h(t - \tau)d\tau \quad (2.6)$$

gdzie $y(t)$ to przefiltrowany sygnał, $x(t)$ to sygnał wejściowy, a $h(t)$ to odpowiedź impulsowa filtra.

2.13.4. Algorytm analizy czasowo-amplitudowej

Sygnał z pętli indukcyjnej jest analizowany pod kątem zmian amplitudy w czasie. Algorytm ten wykrywa zmiany w indukcyjności w zależności od czasu, co pozwala na detekcję pojazdów i klasyfikację ich typów.

$$\Delta t = t_2 - t_1 \quad (2.7)$$

gdzie t_1 i t_2 to momenty początku i końca zmiany sygnału.

2.13.5. Pułapka pętli do sprawdzania prędkości pojazdu

Pułapka oparta na pętli indukcyjnej do pomiaru prędkości pojazdu polega na rozmieszczeniu dwóch pętli indukcyjnych w określonej odległości od siebie na jezdni. Każda z pętli jest używana do wykrywania momentu wjazdu i wyjazdu pojazdu z danej strefy pomiarowej.

2.14. Opis analizy sygnałów z pętli indukcyjnych

Proces pomiaru:

1. **Detekcja wjazdu:** Pierwsza pętla indukcyjna (pętla A) wykrywa wjazd pojazdu na pętlę, co uruchamia zegar.
2. **Detekcja wyjazdu:** Druga pętla indukcyjna (pętla B) wykrywa wjazd pojazdu na pętlę, co zatrzymuje zegar.
3. **Obliczenie prędkości:** Znając czas przejazdu Δt oraz odległość między pętlami L , można obliczyć prędkość pojazdu v .

$$v = \frac{L}{\Delta t} \quad (2.8)$$

gdzie v to prędkość pojazdu, L to odległość między pętlami, a Δt to czas między wykryciem pojazdu przez obie pętle.

Algorytmy detekcji i pomiaru z wykorzystaniem pętli indukcyjnych umożliwiają dokładną klasyfikację pojazdów, co jest kluczowe dla efektywnego monitorowania ruchu drogowego oraz zarządzania infrastrukturą drogową.

2.14. Opis analizy sygnałów z pętli indukcyjnych

Każdy przejazd pojazdu przez pętlę indukcyjną zamontowaną w drodze uruchamia system akwizycji danych, który rejestruje profil magnetyczny pojazdu. Algorytm wykrywania przejazdu opiera się na detekcji narastającego zbocza sygnału, co pozwala na precyzyjne zidentyfikowanie momentu wjazdu i zjazdu pojazdu z pętli.


W początkowej fazie badań, w układzie jednopętlowym, rejestrowano tylko jeden przebieg sygnału dla każdego przejazdu pojazdu. Na rys.2.16 przedstawiono przykład takiego surowego sygnału (RAW) bez przycinania fragmentów przed i po przejeździe oraz bez filtracji szumów.

Następnie sygnał RAW poddawany jest procesowi filtracji. W badaniach przetestowano szeroko stosowane filtry do wygładzania sygnałów czasowych, które pozwalają na eliminację szumów oraz poprawę jakości danych .

Filtr Kalmana

Filtr Kalmana to algorytm wykorzystujący model statystyczny do szacowania zmiennych stanowych systemu dynamicznego na podstawie szeregów czasowych zanieczyszczonych szumem. Jest często stosowany w systemach nawigacyjnych, przetwarzaniu sygnałów i robotyce.

2. Opis systemów WIM



Rysunek 2.16. Sygnał bez przycięcia części sygnału przed najazdem na pętlę i po zjeździe z pętli oraz bez filtracji szumów. Źródło: opracowanie własne

Filtr Kalmana działa w dwóch etapach: predykcji i aktualizacji. W fazie predykcji przewiduje on przyszły stan na podstawie modelu systemu, a w fazie aktualizacji koryguje tę predykcję na podstawie nowych danych pomiarowych [81].

Savitzky-Golay (savgol)

Filtr Savitzky-Golay, znany również jako filtr wygładzający, jest metodą przetwarzania sygnałów, która polega na dopasowaniu wielomianów do lokalnych segmentów danych. Następnie wartości wielomianu w środku segmentu są używane jako wygładzone wartości danych. Główną zaletą tej metody jest to, że może wygładzać dane bez istotnego zniekształcania kształtu oryginalnego sygnału, co jest szczególnie przydatne przy analizie spektroskopowej i innych zastosowaniach naukowych [93].

Triangular Moving Average (TMA)


Triangular Moving Average to rodzaj średniej ruchomej, która wygładza dane szeregów czasowych poprzez nałożenie dwóch prostych średnich ruchomych. Pierwsza średnia ruchoma jest obliczana na podstawie oryginalnych danych, a następnie druga średnia ruchoma jest obliczana na podstawie wyników pierwszej średniej. Efektem jest wygładzenie danych, które jest bardziej intensywne niż w przypadku prostych średnich ruchomych, co pozwala na lepsze odfiltrowanie szumów i wyodrębnienie trendów [72].

Ostatecznie wybrano filtr Savitzky-Golay ze względu na to, że w pozostałych filtrach zauważano, że dla niektórych sygnałów zostawały wygładzane niektóre szczyty i załamania

2.14. Opis analizy sygnałów z pętli indukcyjnych

sygnału co w przypadku profilu magnetycznego sprawia, że zostaje zabranych z sygnału dość dużo informacji, które pozwalają na różnicowanie między klasami.

Następnie sygnał został poddany decymacji. Filtracja i decymacja pozwala nam w tym przypadku znacznie przyspieszyć ekstrakcję cech którymi zasilamy wektor na potrzeby uczenia. Średnio dzięki filtracji i decymacji uzyskujemy ponad 50-krotne przyspieszenie działania co daje nam zejście przetwarzania na poziomie sekund w przypadku sygnału nie filtrowanego i nie decymowanego do milisekund w przypadku sygnału poddanego filtracji i decymacji oczywiście wliczając również w czas przetwarzania sam proces decymacji i filtracji. Sygnał po odfiltrowaniu i decymacji przedstawiono na rys. 2.17.



Rysunek 2.17. Sygnał z pętli indukcyjnej po odfiltrowaniu szumów i decymacji. Źródło: opracowanie własne

Następnie z tak uzyskanego sygnału wyekstrahowano różne wektory cech. W procesie testów oraz analizy danych wektory te zmieniały się a przedstawione tutaj to tylko kilka propozycji najlepszych lub najbardziej optymalnych

Po przeanalizowaniu literatury wybrano dwa podejścia do przetwarzania sygnałów pierwszym było stworzenie wektorów uczących do zastosowania w modelach uczenia maszynowego [24, 62], a drugim było przygotowanie standaryzowanych obrazów na podstawie przebiegów sygnałów do uczenia przy pomocy sztucznych sieci neuronowych [84]. Ze względu na potrzeby wdrożeniowe rozwiązania, zastosowania projektowanych algorytmów przy drodze zabudowanych w szafach z często brakiem dostępu do prądu oraz zasilaniem akumulatorowym zdecydowano, że platformą docelowej implementacji algorytmów będzie raspberry pi pico lub prosty komputer przemysłowy ARK-1123.

2.14.1. Pierwszy wektor cech profilu magnetycznego pojazdu

W pierwszym wektorze, który zaproponowano w ramach niniejszej pracy wzięto pod uwagę cechy wynikające z samego sygnału. Koncepcję wektorów opracowano na podstawie doświadczeń naukowców, którzy opracowywali ogólnie wektory cech do klasyfikacji sygnałów opartych na zmianach napięcia z różnych czujników [24, 30, 39, 62, 98, 99].

Wektor wykorzystano w rozdziale 3.2.4 (częściowo) oraz rozdziale 3.2.5.

1. Pierwszą cechą wektora uczącego jest różnica pomiędzy wartością maksymalną uzyskaną poprzez dopasowanie parabol w punkcie 0 a wartością w pierwszym listku szybkiej transformaty Fouriera (FFT) dla sygnału bazowego.

Aby uzyskać tę cechę, wykorzystano programowanie liniowe do optymalizacji współczynników parabol, które są dopasowywane do wykrytych szczytów w widmie sygnału. W ramach tej metody przygotowywane są trzy wektory: a, b i c, zawierające współczynniki dla równań ograniczeń. Wektor c zawiera współczynniki dla zmiennych, które chcemy zminimalizować. Następnie definiowane są ograniczenia w postaci nierówności, które muszą być spełnione przez uzyskane rozwiązanie. Programowanie liniowe pozwala na znalezienie optymalnych współczynników a, b i c, co umożliwia precyzyjne dopasowanie parabol.

Dopasowane parabole modelują lokalne szczyty w widmie, co pozwala uzyskać bardziej precyzyjne i stabilne wyniki. W przypadku pojazdów należących do tej samej klasy odchylenie standardowe wyników jest znacznie mniejsze w porównaniu do wyników uzyskanych za pomocą zwykłej różnicy między szczytami. Koncepcję tego dopasowania przedstawiono na rys. 2.18.

Zagadnienie można sformułować następująco:

$$\text{Min}_{a_1, c_1, a_2, b_2, c_2} \sum_{i=0}^6 y_i - (a_1 f_i^2 + c_1 + a_2 f_i^2 + b_2 f_i + c_2) \quad (2.9)$$

Warunki:

$$a_1 \leq 0$$


$$a_2 \leq 0$$

$$b_2 = -2a_2 f_{\max}$$

$$Y_0 - (a_1 f_0^2 + c_1 + a_2 f_0^2 + b_2 f_0 + c_2) \geq 0$$

$$Y_1 - (a_1 f_1^2 + c_1 + a_2 f_1^2 + b_2 f_1 + c_2) \geq 0$$

2.14. Opis analizy sygnałów z pętli indukcyjnych



Rysunek 2.18. Koncepcja dopasowania parabol do punktów maksymalnych w FFT.
Źródło: opracowanie własne

⋮

$$Y_6 - (a_1 f_6^2 + c_1 + a_2 f_6^2 + b_2 f_6 + c_2) \geq 0$$

Te równania wyrażają nierówności, które muszą być spełnione dla każdej wartości f_i . Problem polega na znalezieniu optymalnych (minimalnych) odległości parabol od przebiegów FFT. Dodawana do wektora cech jest różnica pomiędzy wartościami maksymalnymi dopasowanych parabol.

2. Drugą cechą wektora uczącego jest różnica pomiędzy wartością maksymalną w punkcie 0 a wartością w pierwszym listku widma uzyskanego za pomocą szybkiej transformaty Fouriera (FFT) na sygnale bazowym.

Niech $X(f)$ oznacza wynik szybkiej transformaty Fouriera (FFT) sygnału bazowego $x(t)$. Różnica pomiędzy wartością maksymalną w punkcie 0 a wartością w pierwszym listku wyniku FFT jest wyrażona wzorem:

$$\Delta X = X(0) - X(f_{\max}) \quad (2.10)$$

gdzie:

- $X(0)$ to wartość maksymalna w punkcie 0,
- $X(f_{\max})$ to wartość w pierwszym listku widma FFT.

2. Opis systemów WIM

3. Trzecią cechą wektora uczącego jest różnica pomiędzy dwoma kolejnymi wartościami maksymalnymi uzyskanymi z wyniku działania Chirp Z-Transform na sygnale bazowym. Wyodrębnienie tej cechy zostało wykonane w zakresie dominujących częstotliwości w sygnale, tj. od 0 do 70 Hz.

Różnica ta jest wyrażona wzorem:

$$\Delta X = \frac{|F_{\text{zoom}}(0) - F_{\text{zoom}}(f_{\text{max}})|}{10^6} \quad (2.11)$$

gdzie:

- $F_{\text{zoom}}(0)$ oznacza amplitudę sygnału dla zerowej częstotliwości (składowa stała) po zastosowaniu Chirp Z-Transform,
 - $F_{\text{zoom}}(f_{\text{max}})$ oznacza amplitudę sygnału dla częstotliwości odpowiadającej pierwszemu wykrytemu szczytowi po zastosowaniu Chirp Z-Transform.
4. Czwartą cechą wektora uczącego jest średnia wartość sygnału, obliczana jako średnia arytmetyczna wszystkich próbek sygnału. Wartość ta jest wyrażona wzorem:

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (2.12)$$

gdzie:

- μ to średnia arytmetyczna próbek,
 - N to liczba próbek w zbiorze danych,
 - x_i to i -ta próbka sygnału.
5. Piątą cechą jest odchylenie standardowe sygnału σ , które mierzy rozproszenie danych wokół średniej:

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2} \quad (2.13)$$

gdzie:

- σ to odchylenie standardowe,
- N to liczba próbek w zbiorze danych,
- x_i to i -ta próbka sygnału,
- μ to średnia arytmetyczna próbek.

2.14. Opis analizy sygnałów z pętli indukcyjnych

6. Szóstą cechą jest moment trzeciego rzędu sygnału:

$$\mu_3 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3 \quad (2.14)$$

gdzie:

- N to liczba próbek w sygnale,
- x_i to i -ta próbka sygnału,
- \bar{x} to średnia wartość sygnału.

7. Siódmą cechą jest minimalna wartość wektora danych:

$$x_{\min} = \min(x(i)) \quad (2.15)$$

gdzie:

- x_{\min} to wartość minimalna w zbiorze danych,
- x_i to próbki sygnału.

8. Ósmą cechą jest maksymalna wartość wektora danych:

$$x_{\max} = \max(x(i)) \quad (2.16)$$

gdzie:

- x_{\max} to wartość maksymalna w zbiorze danych,
- x_i to próbki sygnału.

9. Dziewiątą cechą jest średnia z sumy przekształceń rzędu 0, 1 oraz 2 wyniku działania transformacji falkowej:

$$S_x = \sum Sx_{\text{order}0} + \sum Sx_{\text{order}1} + \sum Sx_{\text{order}2} \quad (2.17)$$

gdzie:

- $Sx_{\text{order}0}$, $Sx_{\text{order}1}$, $Sx_{\text{order}2}$ to sumy wartości przekształcenia falkowego dla poszczególnych rzędów.

Następnie:

$$S_x = \log(|S_x| + \epsilon) \quad (2.18)$$

gdzie:

- $\epsilon = 1 \times 10^{-6}$ to wartość dodawana w celu uniknięcia logarytmu z zera.

2. Opis systemów WIM

Ostatecznie:

$$S_x = \frac{1}{N} \sum_{i=1}^N \log(|S_{x,i}| + \epsilon) \quad (2.19)$$

gdzie:

- N to liczba próbek w S_x ,
- $S_{x,i}$ to i -ta próbka po zastosowaniu przekształcenia falkowego.

10. Dziesiątą cechą jest kurtoza sygnału:

$$Kurtosis = \frac{N(N+1)}{(N-1)(N-2)(N-3)} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^4 - \frac{3(N-1)^2}{(N-2)(N-3)} \quad (2.20)$$

gdzie:

- N to liczba próbek w zbiorze danych,
- x_i to i -ta próbka sygnału,
- μ to średnia arytmetyczna próbek,
- σ to odchylenie standardowe próbek.

11. Jedenastą cechą jest skośność wektora danych:

$$Skewness = \frac{N}{(N-1)(N-2)} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^3 \quad (2.21)$$

gdzie:

- N to liczba próbek w zbiorze danych,
- x_i to i -ta próbka sygnału,
- μ to średnia arytmetyczna próbek,
- σ to odchylenie standardowe próbek.

12. Dwunastą cechą jest wariancja wektora danych:

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2 \quad (2.22)$$

gdzie:

- σ^2 to wariancja,
- N to liczba próbek w zbiorze danych,
- x_i to i -ta próbka sygnału,

2.14. Opis analizy sygnałów z pętli indukcyjnych

- μ to średnia arytmetyczna próbek.

13. Trzynastą cechą jest różnica pomiędzy minimalną a maksymalną wartością sygnału:

$$X_{\max\min} = \max(x_i) - \min(x_i) \quad (2.23)$$

gdzie:

- $\max(x_i)$ to maksymalna wartość w zbiorze danych,
- $\min(x_i)$ to minimalna wartość w zbiorze danych,
- x_i to i -ta próbka sygnału.

14. Czternastą cechą jest pierwiastek z średniej kwadratowej sygnału:

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (2.24)$$

gdzie:

- RMS to pierwiastek średniej kwadratowej,
- N to liczba próbek w zbiorze danych,
- x_i to i -ta próbka sygnału.

15. Piętnastą cechą jest stosunek pierwiastka z średniej kwadratowej sygnału do średniej sygnału:

$$\text{RMS-to-Mean Ratio} = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N y_i^2}}{\frac{1}{N} \sum_{i=1}^N y_i} \quad (2.25)$$

gdzie:

- RMS-to-Mean Ratio to współczynnik pierwiastka średniej kwadratowej do średniej wartości,
- N to liczba próbek w zbiorze danych,
- y_i to i -ta próbka sygnału.

16. Szesnastą cechą jest stosunek maksymalnej wartości sygnału do pierwiastka z średniej kwadratowej sygnału:

$$\text{Peak-to-RMS Ratio} = \frac{\max(x_i)}{\sqrt{\frac{1}{N} \sum_{i=1}^N y_i^2}} \quad (2.26)$$

gdzie:

2. Opis systemów WIM

- Peak-to-RMS Ratio to współczynnik maksymalnej wartości do RMS,
- $\max(x_i)$ to maksymalna wartość w zbiorze danych,
- N to liczba próbek w zbiorze danych,
- y_i to i -ta próbka sygnału.

17. Siedemnastą cechą jest stosunek maksymalnej wartości wektora danych do średniej wartości wektora danych:

$$\text{Peak-to-Mean Ratio} = \frac{\max(x_i)}{\frac{1}{N} \sum_{i=1}^N y_i} \quad (2.27)$$

gdzie:

- Peak-to-Mean Ratio to współczynnik maksymalnej wartości do średniej wartości,
- $\max(x_i)$ to maksymalna wartość w zbiorze danych,
- N to liczba próbek w zbiorze danych,
- y_i to i -ta próbka sygnału.

18. Cechy od osiemnaście do dwadzieścia dwa to pięć współrzędnych (x,y) maksimów w gęstości widmowej mocy (PSD) sygnału:

$$\text{PSD}(f) = \frac{1}{T} |\mathcal{F}\{R_{xx}(t)\}|^2 \quad (2.28)$$

gdzie:

- $\text{PSD}(f)$ to gęstość widmowa mocy dla częstotliwości f ,
- T to całkowity czas obserwacji,
- $\mathcal{F}\{\cdot\}$ to transformata Fouriera,
- $R_{xx}(t)$ to autokorelacja sygnału $x(t)$.

19. Cechy od dwadzieścia trzy do dwadzieścia siedem to pięć kolejnych współrzędnych (x,y) maksimów przekształcenia sygnału przy pomocy transformaty Fouriera autokorelacji FFT:

$$X(f) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi f \frac{n}{N}} \quad (2.29)$$

gdzie:

- $X(f)$ to wartość transformaty Fouriera dla częstotliwości f ,
- $x(n)$ to wartość sygnału w chwili n ,
- N to liczba próbek w sygnale,

2.14. Opis analizy sygnałów z pętli indukcyjnych

- $e^{-j2\pi f \frac{n}{N}}$ to czynnik zespolony reprezentujący oscylację w dziedzinie częstotliwości.

20. Cechy od dwadzieścia osiem do trzydzieści dwa to pięć kolejnych współrzędnych (x,y) maksimum funkcji autokorelacji dla sygnału bazowego:

$$R_{xx}(\tau) = \sum_{n=0}^{N-1} x(n)x(n-\tau) \quad (2.30)$$

gdzie:

- $R_{xx}(\tau)$ to wartość autokorelacji dla opóźnienia τ ,
- $x(n)$ to wartość sygnału w chwili n ,
- τ to opóźnienie.

21. Cechy od trzydzieści trzy do trzydzieści osiem to pięć kolejnych współrzędnych (x,y) maksimum lokalnych transformaty falkowej zerowego rzędu:

$$W(a, b) = \frac{1}{\sqrt{a}} \sum_{n=0}^{N-1} x(n)\psi\left(\frac{n-b}{a}\right) \quad (2.31)$$

gdzie:

- $W(a, b)$ to współczynnik falkowy dla skali a i przesunięcia b ,
- $x(n)$ to wartość sygnału w chwili n ,
- ψ to funkcja falkowa,
- a to skala,
- b to przesunięcie.

Podsumowując, wektor uczący, zawierający cechy uzyskane z sygnału, jest tworzony w następujący sposób:

```
# Tworzenie wektora cech
```

```
vector_of_features = [
    linprog_val,
    normal_val,
    chirp_z_val,
    mean(signal),           # Średnia sygnału
    round(std_deviation(signal), 2), # Odchylenie standardowe
    round(third_moment(signal), 2),  # Moment trzeciego rzędu
    min(signal),           # Wartość minimalna
    max(signal),           # Wartość maksymalna
```

2. Opis systemów WIM

```
Sx,                # Cechy z~przekształcenia rozpraszającego
kurtosis(signal),  # Kurtoza
skewness(signal),  # Skośność
variance(signal),  # Wariancja
peak_to_peak(signal), # Rozstęp
minmax,            # Min-Max
rms(signal),       # Pierwiastek średniej kwadratowej (RMS)
rms(signal) / mean(signal), # Stosunek RMS do średniej
max(signal) / rms(signal), # Stosunek maksymalnej wartości do RMS
max(signal) / mean(signal) # Stosunek maksymalnej wartości do średniej
]

# Dodawanie cech z PSD
psd_features = get_features(f_values, psd_values, mph)
vector_of_features.extend([
    psd_features[0][0], psd_features[0][1],
    psd_features[1][0], psd_features[1][1],
    psd_features[2][0], psd_features[2][1],
    psd_features[3][0], psd_features[3][1],
    psd_features[4][0], psd_features[4][1]
])

# Dodawanie cech z FFT
fft_features = get_features(f_values, fft_values, mph)
vector_of_features.extend([
    fft_features[0][0], fft_features[0][1],
    fft_features[1][0], fft_features[1][1],
    fft_features[2][0], fft_features[2][1],
    fft_features[3][0], fft_features[3][1],
    fft_features[4][0], fft_features[4][1]
])

# Dodawanie cech z autokorelacji
autocorr_features = get_features(x_values, autocorr_values, mph)
vector_of_features.extend([
```

2.14. Opis analizy sygnałów z pętli indukcyjnych

```
autocorr_features[0][0], autocorr_features[0][1],
autocorr_features[1][0], autocorr_features[1][1],
autocorr_features[2][0], autocorr_features[2][1],
autocorr_features[3][0], autocorr_features[3][1],
autocorr_features[4][0], autocorr_features[4][1]
])

# Dodawanie cech z przekształcenia falkowego
wavelet_features = get_features(coeffs, mph)
vector_of_features.extend([
    wavelet_features[0][0], wavelet_features[0][1],
    wavelet_features[1][0], wavelet_features[1][1],
    wavelet_features[2][0], wavelet_features[2][1],
    wavelet_features[3][0], wavelet_features[3][1],
    wavelet_features[4][0], wavelet_features[4][1]
])
```

Dla każdego pojazdu przejeżdżającego przez stację ważenia pojazdów w ruchu tworzony jest taki wektor cech, który następnie zapisywany jest do dalszej analizy.

2.14.2. Drugi wektor cech profilu magnetycznego pojazdu

Drugi wektor cech zawiera cechy statystyczne oraz estymatę długości pojazdu, nazywaną długością magnetyczną. Długość magnetyczna jest obliczana metodą bezpośrednią, znaną jako pułapka pętlowa lub przy pomocy estymatora na podstawie sygnału z jednej pętli.

Wektor wykorzystano w rozdziale 3.2.6.

Każdy pojedynczy sygnał jest przetwarzany i reprezentowany przez wektor 10 cech, jak zaproponowano w artykule [98]. W badaniu wykorzystano następujące cechy:

1. **Maksymalna amplituda** – maksymalna wartość sygnału:

$$x_{\max} = \max(x(i)). \quad (2.32)$$

2. Opis systemów WIM

2. **Średnia** – średnia wartość wszystkich próbek w sygnale:

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i. \quad (2.33)$$

3. **Odchylenie standardowe (Std)** – miara rozproszenia wartości w zbiorze danych:

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2}. \quad (2.34)$$

4. **Kurtoza** – miara ogonów rozkładu prawdopodobieństwa, wskazująca na ciężkość lub lekkość ogonów w porównaniu do rozkładu normalnego:

$$Kurtosis = \frac{N(N+1)}{(N-1)(N-2)(N-3)} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^4 - \frac{3(N-1)^2}{(N-2)(N-3)}. \quad (2.35)$$

5. **Skośność** – miara asymetrii rozkładu prawdopodobieństwa:

$$Skewness = \frac{N}{(N-1)(N-2)} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^3. \quad (2.36)$$

6. **Wariancja** – miara rozproszenia wartości w zbiorze danych:

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2. \quad (2.37)$$

7. **Szczyty** – liczba maksimów lokalnych (tzw. pików) w sygnale. Dla sygnału $x(i)$, liczba pików $len(p_i)$ to suma wszystkich $x(i)$, dla których spełnione są warunki:

$$x(i) > x(i-1) \quad \text{oraz} \quad x(i) > x(i+1), \quad \text{dla } 1 < i < N. \quad (2.38)$$

8. **Średnia pików** – średnia wartość pików w sygnale:

$$Peaks Mean = \frac{1}{M} \sum_{i=1}^M p_i. \quad (2.39)$$

2.14. Opis analizy sygnałów z pętli indukcyjnych

9. **Obszar** – określa rozmiar obszaru na wykresie, ograniczonego krzywą sygnału:

$$Area = \sum_{i=1}^{N-1} \frac{(x_{i+1} + x_i) \cdot dD}{2}, \quad (2.40)$$

gdzie dD oznacza elementarny krok na osi odległości.

10. **Długość magnetyczna** – obliczana na podstawie prędkości v i czasu t_{occ} , w którym pojazd zajmuje pole szerokiego czujnika IL. Zwykle jest ona dłuższa niż rzeczywista długość pojazdu i zależy od czułości czujnika IL, dlatego wymaga odjęcia poprawki L_w :

$$Magnetic\ Length = v \cdot t_{occ} - L_w. \quad (2.41)$$

Ostatecznie wektor cech tworzony dla każdego sygnału z każdego przejazdu wygląda następująco:

```
// Lista cech sygnału
features = [
    x_max,          // Maksymalna amplituda
    mu,             // Średnia
    std_dev,        // Odchylenie standardowe
    kurtosis,       // Kurtoza
    skewness,       // Skośność
    variance,       // Wariancja
    peaks_count,    // Liczba pików
    peaks_mean,     // Średnia pików
    area,           // Obszar
    magnetic_length // Długość magnetyczna
]

// Zwracanie wektora cech
return features
```

2.14.3. Trzeci wektor cech profilu magnetycznego pojazdu – estymacja prędkości pojazdu

Trzeci wektor cech wykorzystano w rozdziale 3.2.7. Składa się z cech statystycznych uzyskanych z sygnału z jednej pętli. Każdy pojedynczy sygnał jest przetwarzany i reprezentowany przez wektor 9 cech, jak zaproponowano w artykule [74]. Autorzy tego artykułu stworzyli

2. Opis systemów WIM

model statystyczny, który na podstawie wyodrębnionych cech i odpowiedniego równania szacował prędkość pojazdu. W związku z tym przeprowadzono badanie, które polegało na wykorzystaniu zaproponowanego przez autorów wektora cech i zastosowaniu modeli uczenia maszynowego do estymacji prędkości pojazdu. W badaniu wykorzystano następujące cechy:

1. **2 levels Slew Rate (SR_2)** – wartość SR_2 obliczana jako maksymalna wartość bezwzględnej różnicy gradientów profilu magnetycznego przy różnych krokach czasowych:

$$SR_2 = \max \left(\left| \frac{\partial \text{magnetic_profile}}{\partial t_1} - \frac{\partial \text{magnetic_profile}}{\partial t_2} \right| \right) \quad (2.42)$$

gdzie $t_1 = 0,1[ms]$, $t_2 = 0,6[ms]$.

2. **Slew Rate (SR_local)** – SR_local obliczana jako maksymalna wartość bezwzględnej różnicy gradientów profilu magnetycznego przy kroku czasowym 0,1 i pierwszym pikie profilu:

$$SR_{\text{local}} = \max \left(\left| \frac{\partial \text{magnetic_profile}}{\partial t_1} - \frac{\partial \text{magnetic_profile}}{\partial t_{\text{peak}}} \right| \right), \quad (2.43)$$

gdzie $t_1 = 0,1[ms]$ oraz $t_{\text{peak}}[ms]$ to czas pierwszego pikie.

3. **Slew Rate (SR_global)** – SR_global obliczana jako maksymalna wartość bezwzględnej różnicy gradientów profilu magnetycznego przy kroku czasowym 0.1 i globalnym maksimum profilu:

$$SR_{\text{global}} = \max \left(\left| \frac{\partial \text{magnetic_profile}}{\partial t_1} - \frac{\partial \text{magnetic_profile}}{\partial t_{\text{max}}} \right| \right), \quad (2.44)$$

gdzie $t_1 = 0,1[ms]$ oraz $t_{\text{max}}[ms]$ to czas globalnego maksimum profilu.

4. **Duration (dur)** – czas trwania sygnału liczony jako długość profilu magnetycznego:

$$\text{dur} = \text{len}(\text{magnetic_profile}). \quad (2.45)$$

5. **Inverse duration (Inv(dur))** – odwrotność czasu trwania sygnału:

$$\text{Inv}(\text{dur}) = \frac{1}{\text{dur}}. \quad (2.46)$$

2.14. Opis analizy sygnałów z pętli indukcyjnych

6. **Parabolic model (Max(dxdt(p)))** – maksymalna wartość pochodnej modelu parabolicznego aproksymującego profil magnetyczny:

$$\text{Max}(dxdt(p)) = \max \left(\frac{d}{dt} \text{polynomial_approximation}(\text{magnetic_profile}) \right). \quad (2.47)$$

7. **Numerical derivative (Max(NumDiff))** – maksymalna wartość numerycznej pochodnej profilu magnetycznego:

$$\text{Max}(\text{NumDiff}) = \max \left(\frac{d}{dt} \text{magnetic_profile} \right). \quad (2.48)$$

8. **Profile line length (Len)** – długość linii profilu magnetycznego liczona jako suma bezwzględnych różnic kolejnych wartości profilu:

$$\text{Len} = \sum |\text{diff}(\text{magnetic_profile})|. \quad (2.49)$$

9. **Area (A)** – pole pod krzywą profilu magnetycznego liczone metodą trapezów:

$$A = \int \text{magnetic_profile} dt. \quad (2.50)$$

Ostatecznie wektor cech, który jest zwracany dla każdego sygnału, wygląda następująco:

```
# Wektor cech
features = [
    sr_2,
    sr_local,
    sr_global,
    duration,
    inv_duration,
    max_derivative,
    numerical_derivative,
    profile_length,
    area
]

# Zwracanie wektora cech
return features
```

2.14.4. Czwarty wektor cech profilu magnetycznego – estymacja liczby osi i długości pojazdu

Czwarty wektor cech zaproponowany w ramach pracy opiera się na analizie cech częstotliwościowych uzyskanych z sygnału. Zgodnie z opisem zawartym w [71], wykrycie osi pojazdu jest możliwe na podstawie analizy zmian części rzeczywistej oraz urojonej sygnału zarejestrowanego podczas przejazdu pojazdu nad pętlą indukcyjną. W związku z tym przeprowadzono badania mające na celu sprawdzenie, czy w poszczególnych częstotliwościach części urojonej sygnału można znaleźć powiązanie między maksimami tych częstotliwości a liczbą osi pojazdu oraz analogicznie sprawdzić czy istnieje taka zależność do długości magnetycznej pojazdu.

Wektor wykorzystano w rozdziale 3.2.2.

Opracowany wektor cech składa się z maksimów uzyskanych w wyniku zastosowania Chirp Z-Transform (CZT) na sygnale bazowym. Wyodrębnienie tych cech zostało przeprowadzone w zakresie dominujących częstotliwości sygnału, tj. od 0 do 100 Hz.

Zostało to wyrażone wzorem:

$$X = F_{\text{zoom}}(f_{\text{max}}) \quad (2.51)$$

gdzie:

- $F_{\text{zoom}}(f_{\text{max}})$ oznacza amplitudę sygnału dla częstotliwości odpowiadającej pierwszemu wykrytemu szczytowi po zastosowaniu Chirp Z-Transform.

Wektor zakresów częstotliwości

```
chirp_keys = [
    "chirp0_1",
    "chirp1_2",
    "chirp2_3",
    # ...
    "chirp99_100",
    "chirp0_10",
    "chirp10_20",
    # ...
    "chirp90_100",
    "chirp0_5",
    "chirp5_10",
```

2.15. Analiza czynnikowa wektorów cech

```
# ...
"chirp95_100",
"chirp0_10",
"chirp0_20",
# ...
"chirp0_100"
]

# Zwracanie słownika z wynikami
return chirp_dict
```

2.15. Analiza czynnikowa wektorów cech

Analiza czynnikowa jest powszechnie stosowana do redukcji wymiarów oraz odkrywania ukrytych struktur w zbiorach danych. Do najczęściej wykorzystywanych metod należą analiza składowych głównych (PCA), analiza niezależnych składowych (ICA) oraz analiza czynnikowa (FA). Metody te zostały szczegółowo opisane w pracach [9] oraz [96]. Zastosowanie analizy czynnikowej jest szczególnie uzasadnione w przypadkach dużych wektorów danych do klasyfikacji, ponieważ dzięki tym metodom możliwe jest ograniczenie liczby cech w wektorze, co znacznie skraca czas obliczeń. Wektory cech omawiane w niniejszej pracy były poddawane analizie czynnikowej, jednak nie zawsze zdecydowano się na jej ostateczne wdrożenie, ze względu na zbyt dużą utratę dokładności klasyfikacji.

2.15.1. Analiza składowych głównych (PCA)

Analiza składowych głównych (*Principal Component Analysis*, PCA) – jej celem jest przekształcenie oryginalnych zmiennych na nowy zestaw zmiennych, zwanych składowymi głównymi. Składowe te są liniowymi kombinacjami oryginalnych zmiennych i są ortogonalne względem siebie, co oznacza, że są nieskorelowane.

PCA działa poprzez znalezienie kierunków (składowych), wzdłuż których rozrzut danych jest największy, czyli tam, gdzie dane mają największą wariancję. Matematycznie, składowe główne są wynikiem rozwiązania problemu własnych wartości dla macierzy kowariancji danych \mathbf{X} :

2. Opis systemów WIM

$$\mathbf{C} = \frac{1}{n-1} \mathbf{X}^T \mathbf{X}, \quad (2.52)$$

gdzie \mathbf{C} to macierz kowariancji, a \mathbf{X} to macierz danych. Następnie, rozwiązujemy równanie własne:

$$\mathbf{C}\mathbf{v}_i = \lambda_i \mathbf{v}_i, \quad (2.53)$$

gdzie λ_i to i -ta wartość własna, a \mathbf{v}_i to i -ty wektor własny. Składowe główne to linie, wzdłuż których projekcje danych mają największą wariancję:

$$\mathbf{Z} = \mathbf{X}\mathbf{V}, \quad (2.54)$$

gdzie \mathbf{Z} to macierz danych przekształconych do nowej przestrzeni składowych głównych, a \mathbf{V} to macierz wektorów własnych (składowych głównych).

2.15.2. Analiza składowych niezależnych (ICA)

Analiza składowych niezależnych (*Independent Component Analysis*, ICA) różni się od PCA tym, że celem jest znalezienie składowych, które są statystycznie niezależne od siebie, a nie tylko nieskorelowane.

Model ICA można zapisać jako:

$$\mathbf{X} = \mathbf{A}\mathbf{S}, \quad (2.55)$$

gdzie \mathbf{X} to obserwowane dane, \mathbf{A} to macierz mieszająca, a \mathbf{S} to macierz niezależnych źródeł.

2.15.3. Analiza czynnikowa (FA)

Analiza czynnikowa (*Factor Analysis*, FA) to kolejna technika redukcji wymiarów, która ma na celu identyfikację ukrytych zmiennych (czynników) wyjaśniających wzorce współzależności w zbiorze danych. Model FA zakłada, że każda obserwowana zmienna x_j może być wyrażona jako liniowa kombinacja ukrytych czynników f_k oraz błędu pomiaru ϵ_j :

$$x_j = \lambda_{j1}f_1 + \lambda_{j2}f_2 + \cdots + \lambda_{jm}f_m + \epsilon_j, \quad (2.56)$$

2.16. Klasyfikatory, regresory oraz inne algorytmy analizy sygnałów z pętli indukcyjnych

gdzie λ_{jk} to ładunki czynnikowe, które mierzą wpływ czynnika f_k na zmienną x_j .

W notacji macierzowej, model FA można zapisać jako:

$$\mathbf{X} = \mathbf{L}\mathbf{F} + \mathbf{E}, \quad (2.57)$$

gdzie \mathbf{X} to macierz obserwacji, \mathbf{L} to macierz ładunków czynnikowych, \mathbf{F} to macierz czynników, a \mathbf{E} to macierz błędów pomiarowych.

2.16. Klasyfikatory, regresory oraz inne algorytmy analizy sygnałów z pętli indukcyjnych

W ramach badań wykorzystano kilka powszechnie używanych klasyfikatorów oraz regresorów [5, 24, 30, 39, 62, 98, 99]. Algorytmy uczenia maszynowego umożliwiają analizę złożonych zbiorów danych i pozwalają na identyfikację głębokich relacji między cechami, co prowadzi do dokładniejszych wyników klasyfikacji i prognoz. Dzięki przetwarzaniu i analizie dużych zbiorów danych, algorytmy te są w stanie wykrywać zależności i wzorce w danych. W badaniach zastosowano różne modele w celu lepszego zrozumienia danych i identyfikacji zależności. Wybór odpowiedniego algorytmu zależy od specyfiki problemu, struktury danych, ich dokładności oraz celów optymalizacji.

2.16.1. Przegląd zastosowanych algorytmów

W niniejszych badaniach wykorzystano zarówno standardowe, jak i złożone modele do analizy danych oraz poprawy dokładności przewidywań. Niniejsza sekcja zawiera przegląd zastosowanych algorytmów wraz z krótkimi opisami. Algorytmy te zostały wybrane ze względu na ich popularność, skuteczność oraz różnorodność w kontekście analizy danych. Bardziej szczegółowe objaśnienia poszczególnych algorytmów można znaleźć w literaturze [9, 11].

Regresja logistyczna

Regresja logistyczna jest jednym z najczęściej stosowanych algorytmów do rozwiązywania problemów klasyfikacji binarnej. Metoda ta jest wykorzystywana, gdy wynik (zmienna zależna) jest dychotomiczny, tj. przyjmuje jedną z dwóch możliwych wartości. Algorytm ten analizuje relacje między zestawem zmiennych niezależnych (cech) a zmienną zależną, aby oszacować

2. Opis systemów WIM

prawdopodobieństwo wystąpienia jednego z dwóch możliwych wyników. Regresja logistyczna wykorzystuje funkcję logistyczną do modelowania prawdopodobieństw:

$$P(Y = 1|X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}}, \quad (2.58)$$

gdzie $\beta_0, \beta_1, \dots, \beta_n$ są współczynnikami modelu, X_1, X_2, \dots, X_n to zmienne niezależne, a Y to zmienna zależna [64].

Naive Bayes

Naive Bayes to rodzina prostych, ale bardzo efektywnych algorytmów klasyfikacyjnych opartych na twierdzeniu Bayesa. Zakładając, że cechy w zbiorze danych są nieskorelowane, algorytm ten jest szczególnie szybki i łatwy do implementacji. Naive Bayes oblicza prawdopodobieństwo przynależności danego przykładu do każdej z klas za pomocą następującego wzoru:

$$P(C_k|X) = \frac{P(C_k) \prod_{i=1}^n P(X_i|C_k)}{P(X)}, \quad (2.59)$$

gdzie $P(C_k|X)$ jest prawdopodobieństwem klasy C_k dla danego wektora cech X , $P(C_k)$ to prawdopodobieństwo a priori klasy C_k , $P(X_i|C_k)$ to prawdopodobieństwo warunkowe cechy X_i przy danej klasie C_k , a $P(X)$ to całkowite prawdopodobieństwo wektora cech [101].

K-Nearest Neighbors (K-NN)

Algorytm *K-Nearest Neighbors* (K-NN) jest jednym z najprostszych algorytmów klasyfikacyjnych, który opiera się na zasadzie podobieństwa. Klasyfikacja nowego punktu danych odbywa się poprzez analizę klas jego najbliższych sąsiadów (punktów danych o najbliższym dystansie w przestrzeni cech). W przypadku K-NN dystans najczęściej mierzy się za pomocą metryki euklidesowej:

$$d(X, Y) = \sqrt{\sum_{i=1}^n (X_i - Y_i)^2}, \quad (2.60)$$

gdzie X i Y to dwa wektory cech, a $d(X, Y)$ to dystans euklidesowy między nimi [86].

Support Vector Classifier (SVC)

Support Vector Classifier (SVC) to potężny algorytm klasyfikacyjny, który dąży do znalezienia optymalnej hiperpłaszczyzny zdolnej do oddzielenia różnych klas w danych wejściowych. SVC działa na zasadzie maksymalizacji marginesu – czyli odległości między hiperpłaszczyzną a najbliższymi punktami danych z każdej klasy (zwanymi wektorami nośnymi). Model SVC można sformułować jako problem optymalizacji:

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2, \quad (2.61)$$

z ograniczeniami:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1.$$

gdzie \mathbf{w} to wektor wag, b to przesunięcie, y_i to etykieta klasy dla przykładu \mathbf{x}_i [26].

Drzewo decyzyjne

Drzewo decyzyjne to intuicyjny i łatwy do interpretacji algorytm uczenia maszynowego, który podejmuje decyzje na podstawie sekwencyjnych podziałów danych. Algorytm działa poprzez iteracyjne dzielenie danych na podzbiory w oparciu o kryteria maksymalizacji zysku informacji lub minimalizacji nieczystości. Przykładem popularnego kryterium jest wskaźnik Ginięgo:

$$Gini(t) = 1 - \sum_{i=1}^n (p_i)^2, \quad (2.62)$$

gdzie p_i to udział klasy i w węźle t . Proces ten prowadzi do liści, które reprezentują ostateczne klasyfikacje.

Las losowy

Las losowy (*Random Forest*) jest złożonym modelem uczenia maszynowego, który łączy wyniki wielu drzew decyzyjnych, aby poprawić dokładność klasyfikacji i zredukować ryzyko nadmiernego dopasowania (*overfitting*). Każde drzewo w lesie losowym jest budowane na losowym podzbiórze danych i cech, co wprowadza różnorodność i stabilność do modelu. Ostateczna klasyfikacja jest uzyskiwana na podstawie głosowania większościowego wyników z wszystkich drzew:

2. Opis systemów WIM

$$\hat{y} = \text{mode}\{h_1(x), h_2(x), \dots, h_B(x)\}, \quad (2.63)$$

gdzie h_i to klasyfikator w i -tym drzewie, a B to liczba drzew w lesie.

Voting Classifier

Voting Classifier to meta-algorytm, który łączy wyniki z różnych modeli klasyfikacyjnych, aby uzyskać bardziej stabilne i dokładne przewidywania. Działanie tego algorytmu polega na oddawaniu głosów przez poszczególne modele na określoną klasę dla danego przykładu, a ostateczna decyzja jest podejmowana na podstawie większości głosów. Podejście to pozwala na wykorzystanie zalet różnych algorytmów i redukcję ich indywidualnych słabości. *Voting Classifier* może być stosowany z algorytmami takimi jak regresja logistyczna, drzewa decyzyjne czy SVC.

Artificial Neural Network (ANN)

Artificial Neural Network (ANN) to zaawansowany model inspirowany strukturą biologicznych sieci neuronowych, zdolny do rozpoznawania skomplikowanych wzorców w danych. W naszym badaniu zastosowano klasyfikator wielowarstwowy perceptron (MLP) z trzema warstwami ukrytymi, zawierającymi odpowiednio 100, 50 i 25 neuronów. Sieć wykorzystuje funkcję aktywacji ReLU oraz optymalizator Adam, a proces treningowy jest skonfigurowany na maksymalnie 300 iteracji z inicjalizacją *random state* = 42. Proces propagacji wstecznej w ANN opiera się na minimalizacji funkcji straty, takiej jak średni błąd kwadratowy:

$$L = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (2.64)$$

gdzie y_i to rzeczywista wartość, a \hat{y}_i to przewidywana wartość.

YOLO (You Only Look Once)

YOLO (*You Only Look Once*) [43] to zaawansowany algorytm wykorzystywany do detekcji obiektów w obrazach i wideo. W przeciwieństwie do tradycyjnych metod detekcji, które wymagają przeprowadzenia klasyfikacji na wielu regionach obrazu, YOLO traktuje detekcję obiektów jako problem regresji, jednocześnie przewidując bounding boxy i klasy dla tych boxów w jednym przebiegu sieci. Sieć YOLO dzieli obraz na siatkę, a każda komórka siatki

2.17. Analiza sygnałów z wag

przewiduje bounding box i prawdopodobieństwo klasy obiektu w tym boxie. Model YOLO jest trenowany za pomocą funkcji straty, która uwzględnia zarówno błąd położenia bounding boxów, jak i błąd klasyfikacji:

$$\begin{aligned} \text{Loss} = \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{\text{obj}} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 + (\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2] + \\ + \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{\text{obj}} (C_i - \hat{C}_i)^2 + \lambda_{\text{noobj}} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{\text{noobj}} (C_i - \hat{C}_i)^2 + \\ + \sum_{i=0}^{S^2} \mathbb{1}_i^{\text{obj}} \sum_{c \in \text{classes}} (p_i(c) - \hat{p}_i(c))^2 \quad (2.65) \end{aligned}$$

gdzie S to liczba komórek siatki, B to liczba przewidywanych bounding boxów na komórkę, $\mathbb{1}_{ij}^{\text{obj}}$ jest wskaźnikiem, czy bounding box j w komórce i zawiera obiekt, x, y, w, h to współrzędne i wymiary przewidywanego boxu, C to zaufanie co do boxu, a $p(c)$ to przewidywane prawdopodobieństwo klasy c .

YOLOX jest zaawansowaną wersją architektury YOLO, charakteryzującą się ulepszonymi mechanizmami detekcji obiektów oraz efektywniejszym zarządzaniem równowagą między dokładnością a szybkością predykcji. Główne komponenty YOLOX to *backbone*, *neck* oraz *head*, które odpowiedzialne są za ekstrakcję cech, fuzję informacji oraz końcową predykcję. Na rysunku 2.19 przedstawiono schemat architektury YOLOX.

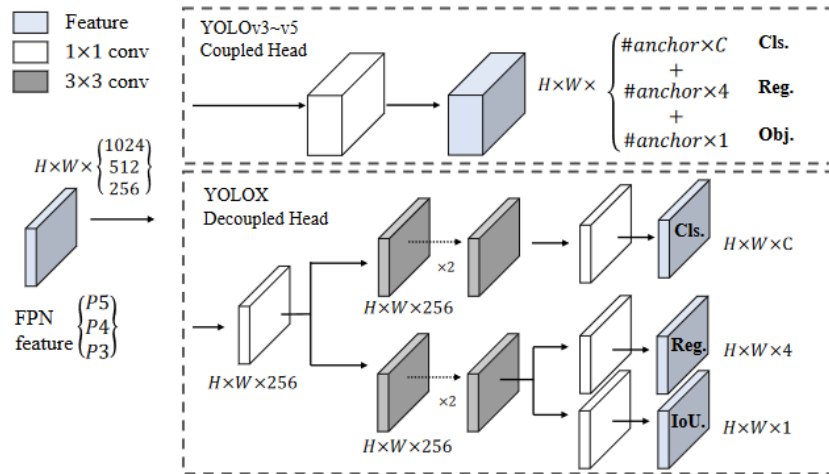
YOLO jest szczególnie skuteczny w zadaniach wymagających szybkiej i dokładnej detekcji obiektów w obrazach i wideo, co czyni go popularnym wyborem w aplikacjach takich jak monitorowanie w czasie rzeczywistym, rozpoznawanie twarzy czy autonomiczne pojazdy.

YOLOX jest trenowany za pomocą strategii, która łączy techniki *augmentacji*, takie jak *Mosaic* i *MixUp*, co znacząco poprawia zdolność generalizacji modelu. Ponadto YOLOX korzysta z dynamicznego algorytmu uczącego, który optymalizuje zarówno precyzję detekcji, jak i szybkość obliczeń.

2.17. Analiza sygnałów z wag

Sygnał z wag wykazuje na początku pewne zaszumienie, dlatego przed poddaniem go analizie wykonano wygładzenie oraz normalizację sygnału. Zastosowano metodę wygładzania sygnału z wykorzystaniem okna trójkątnego.

2. Opis systemów WIM



Rysunek 2.19. Ilustracja różnicy między głową YOLOv3 a proponowaną głową odłączoną.

Dla każdego poziomu funkcji FPN najpierw przyjmujemy warstwę konwolucji 1×1 , aby zredukować kanał funkcji do 256, a następnie dodajemy dwie równoległe gałęzie z dwiema warstwami konwolucji 3×3 każda odpowiednio dla zadań klasyfikacji i regresji. Gałąź IoU jest dodawana do gałęzi regresji. Źródło: [43]

2.17.1. Próbkowanie sygnału

W pierwszym kroku sygnał jest poddawany decymacji, co pozwala na redukcję liczby punktów danych bez utraty istotnych informacji:

```
data = scipy.signal.decimate(data, 10, n=None,
                             ftype='fir', axis=-1, zero_phase=True). (2.66)
```

2.17.2. Definicja okna trójkątnego

Okno trójkątne jest definiowane jako wektor o długości $2 \cdot \text{degree} + 1$, który rośnie liniowo do środka, a następnie maleje liniowo:

$$\text{triangle} = [0, 1, 2, \dots, \text{degree}, \text{degree}-1, \dots, 1]. \quad (2.67)$$

2.17.3. Wygładzanie sygnału

Sygnał jest wygładzany przez przesuwanie okna trójkątnego po danych wejściowych i obliczanie średniej ważonej dla każdego punktu. W ten sposób powstaje nowy sygnał wygładzony:

$$\text{smoothed}[i] = \frac{\sum_{j=0}^{2 \cdot \text{degree}} \text{data}[i + j] \cdot \text{triangle}[j]}{\sum_{j=0}^{2 \cdot \text{degree}} \text{triangle}[j]}. \quad (2.68)$$

2.17.4. Rozszerzenie wygładzonego sygnału

Aby zachować długość sygnału, początkowe i końcowe wartości są uzupełniane odpowiednio:

$$\begin{aligned} \text{smoothed} = & [\text{smoothed}[0] \cdot \text{int}(\text{degree} + \text{degree}/2)] + \text{smoothed} \\ & + [\text{smoothed}[-1] \cdot \text{int}(\text{degree} + \text{degree}/2)]. \end{aligned} \quad (2.69)$$

2.17.5. Normalizacja sygnału

Po wygładzeniu sygnał jest normalizowany, aby usunąć przesunięcie offsetu. Offset jest obliczany jako średnia wartość w końcowej części sygnału, gdzie zakłada się brak istotnych zmian wartości:

$$\text{offset} = \frac{\sum_{i=k}^n \text{smoothed}[i]}{n - k}. \quad (2.70)$$

Następnie offset jest odejmowany od każdego punktu sygnału:

$$\text{normalized_smoothed}[i] = \text{smoothed}[i] - \text{offset}. \quad (2.71)$$

2.17.6. Metody odczytu masy

Na wygładzonych i znormalizowanych sygnałach przetestowano trzy metody odczytu masy oraz zaproponowano czwartą metodę z wykorzystaniem modeli uczenia maszynowego.

2. Opis systemów WIM

Metoda 1 – odczyt maksymalnej wartości

Metoda ta polega na znalezieniu maksymalnej wartości sygnału z wygładzonego wykresu danych. Jest to najprostsza metoda, zakładająca, że maksymalna wartość sygnału odpowiada maksymalnej masie:

$$\text{masa}_{\max} = \max(\text{sygnał}). \quad (2.72)$$

Metoda 2 – całkowanie sygnału

Druga metoda polega na całkowaniu sygnału w celu obliczenia masy. Całkowanie jest przeprowadzane za pomocą metody trapezoidalnej (`scipy.integrate.simps`), która oblicza pole pod krzywą sygnału:

$$\text{masa} = \int \text{sygnał} dt. \quad (2.73)$$

Metoda 3 – próbkowanie i rekonstrukcja

Trzecia metoda polega na ponownym próbkowaniu sygnału za pomocą metody `resample` z pakietu `Scipy`. Sygnał jest resampłowany, a następnie integrowany w celu obliczenia masy:

$$\text{masa} = \sum_{i=0}^{N-1} \text{sygnał}_i. \quad (2.74)$$

Metoda 4 – predykcja masy za pomocą modelu uczenia maszynowego

Czwarta metoda obliczania masy pojazdu wykorzystuje model regresji lasu losowego `RandomForestRegressor` do przewidywania masy na podstawie wartości maksymalnych pików surowych sygnałów zarejestrowanych przez wagi wykonane w technologii tensometrycznej.

Ekstrakcja wartości maksymalnych pików. Z surowych sygnałów z czujników wagowych ekstrahuje się wartości maksymalne dla każdego pików:

2.17. Analiza sygnałów z wag

$$\text{max_value}_{i,j} = \max(\text{datavector}_{i,j}), \quad (2.75)$$

gdzie: $\text{max_value}_{i,j}$ – wartość maksymalna j -tego pików w i -tym wektorze danych,
 $\text{datavector}_{i,j}$ – j -ty pik w i -tym wektorze danych.

Przygotowanie danych do trenowania modelu. Przygotowujemy zestawy danych wejściowych X oraz wartości wyjściowe y do trenowania modelu. Dane wejściowe X są przygotowywane na podstawie wartości maksymalnych pików:

$$X = \begin{bmatrix} \text{max_value}_{3,1} & \text{max_value}_{3,2} & \text{max_value}_{4,1} & \text{max_value}_{4,2} \\ \vdots & \vdots & \vdots & \vdots \end{bmatrix}. \quad (2.76)$$

Wartości wyjściowe y są znanymi wartościami nacisku poszczególnych kół pojazdu:

$$y = [w_i], \quad (2.77)$$

gdzie: w_i – nacisk i -tego koła.

Trenowanie modelu. Model regresji lasu losowego jest trenowany na przygotowanych danych:

$$\text{RF} = \text{RandomForestRegressor}(n_estimators=100, \text{random_state}=42). \quad (2.78a)$$

$$\text{RF}.fit(X_{\text{learn}}, y) \quad (2.78b)$$

Przewidywanie mas. Po wytrenowaniu modelu, używamy go do przewidywania mas kół na podstawie zestawu wartości maksymalnych pików:

$$\hat{y} = \text{RF}.predict(X_{\text{test}}). \quad (2.79)$$

Przewidywane masy kół są następnie sumowane, aby uzyskać masę całkowitą:

$$\text{Masa_calkowita} = \sum_{i=1}^4 \hat{y}_i. \quad (2.80)$$

2.18. Ocena dokładności ważenia pojazdów w ruchu

Kolejnym algorytmem, który łączy w sobie dane nie tylko z sygnałów wagowych, ale także z innych istotnych parametrów, jest algorytm logiki rozmytej (*Fuzzy Logic*).

Algorytm logiki rozmytej (*Fuzzy Logic*)

Fuzzy Logic czyli logika rozmyta, jest zaawansowaną metodą stosowaną w analizie danych, która pozwala na modelowanie nieprecyzyjnych i niejednoznacznych informacji. W przeciwieństwie do klasycznej logiki dwuwartościowej, która operuje wyłącznie na wartościach prawdy 0 i 1, logika rozmyta wprowadza pojęcie stopnia przynależności, który może przyjmować dowolną wartość w zakresie od 0 do 1. Jest to szczególnie użyteczne w sytuacjach, gdzie dane są niejasne lub niekompletne.

W kontekście analizy parametrów i wyliczania prawdopodobieństwa błędu pomiarowego, logika rozmyta pozwala na uwzględnienie niepewności i zmienności danych. Proces analizy z wykorzystaniem logiki rozmytej składa się z następujących kroków:

1. **Fuzzification (rozmywanie):** Przekształcenie wartości wejściowych (parametrów) na rozmyte zmienne językowe z przypisanymi funkcjami przynależności. Przykładem funkcji przynależności może być trójkątna funkcja przynależności:

$$\mu_A(x) = \begin{cases} 0 & \text{dla } x \leq a \\ \frac{x-a}{b-a} & \text{dla } a < x \leq b \\ \frac{c-x}{c-b} & \text{dla } b < x \leq c \\ 0 & \text{dla } x > c \end{cases} \quad (2.81)$$

gdzie a, b, c to punkty określające kształt funkcji przynależności.

2. **Inference (wnioskowanie):** Stosowanie reguł wnioskowania rozmytego (IF-THEN) do przekształcenia rozmytych zmiennych wejściowych na rozmyte zmienne wyjściowe. Przykład reguły: "IF temperatura jest wysoka AND wilgotność jest niska THEN prawdopodobieństwo błędu pomiarowego jest małe".
3. **Defuzzification (wyostrzanie):** Przekształcenie rozmytych zmiennych wyjściowych na wartości ostre. Jedną z metod wyostrzania jest metoda środka ciężkości:

$$y = \frac{\sum_{i=1}^n \mu_C(y_i) \cdot y_i}{\sum_{i=1}^n \mu_C(y_i)}, \quad (2.82)$$

2.19. Klasyfikacja pojazdów

gdzie $\mu_C(y_i)$ to funkcje przynależności wyjściowych zmiennych rozmytych, a y_i to wartości wyjściowe.

Stosowanie logiki rozmytej do analizy kilku parametrów i wyliczania prawdopodobieństwa błędu pomiarowego pozwala na elastyczne i dokładne uwzględnienie niepewności oraz zmienności danych. Dzięki temu możliwe jest uzyskanie bardziej precyzyjnych wyników w ocenie dokładności ważenia pojazdów w ruchu, co jest szczególnie istotne w kontekście dynamicznych warunków pomiarowych.

2.19. Klasyfikacja pojazdów

Klasyfikacja pojazdów polega na przypisaniu konkretnego pojazdu do określonego wzorca, co pozwala na ocenę jego zgodności z przepisami dotyczącymi wagi i wymiarów. Celem klasyfikacji jest zwiększenie bezpieczeństwa ruchu drogowego oraz regulacja obciążenia infrastruktury drogowej.

Istnieje kilka głównych, najczęściej używanych systemów klasyfikacji pojazdów, takich jak COST 323 [48], TLS 2012 [7] oraz FHWA [33]. Polski standard, stosowany przez Generalną Dyрекcyję Dróg Krajowych i Autostrad (GDDKiA), jest zgodny ze standardem TLS 2012. Coraz częściej wykorzystywany jest także standard klasyfikacji EURO 13 [80]. Najbardziej złożonym systemem jest brazylijski system klasyfikacji pojazdów, który rozróżnia 16 podstawowych kategorii, a wraz z podkategoriami obejmuje ponad 150 klas ciężarówek [73].

Głównym standardem klasyfikacji, który wzięto pod uwagę przy tworzeniu klasyfikatorów w niniejszym badaniu, był standard TLS 2012 8+1 [7], ze względu na jego implementację przez GDDKiA w Polsce. Na rys. 2.20 przedstawiono kategoryzację pojazdów według standardu TLS.

2.20. Środowiska operacyjne oraz platformy sprzętowe

Wytworzone rozwiązania były testowane i wdrażane w różnych środowiskach operacyjnych, dostarczając potrzebnej mocy obliczeniowej. Poniżej przedstawiono opis wykorzystanych platform sprzętowych:

2.20.1. ARK-2121

Wykorzystanie: Przetwarzanie i ocena danych z czujników nacisku.

2. Opis systemów WIM

Description of the vehicle categories with code according to the TLS									
Classification group									
1	64 (vehicle)								
2	32 (car or similar)				33 (lorry or similar)				
5+1	6		1		2	3		4	5
8+1	6	10	7	11	2	3	8	9	5
Basic classification	Other vehicle	Motor-cycle / moped	Car	Van	Car trailer	Lorry	Lorry trailer	Tractor vehicle	Bus

Rysunek 2.20. Schematy klasyfikacji według TLS. Źródło: <https://www.bast.de> (dostęp: 07.2024) [7]

ARK-2121 to komputer przemysłowy wyposażony w następujące komponenty:

- 8GB pamięci RAM,
- 240 GB dysk SSD,
- 4-rdzeniowy procesor Intel Celeron J1900,
- System operacyjny: Linux.

Platforma ta została wykorzystana głównie do przetwarzania i analizy danych pochodzących z czujników nacisku.

2.20.2. ARK-1123

Wykorzystanie: Klasyfikatory, przetwarzanie danych z pętli indukcyjnych.

ARK-1123 to komputer przemysłowy o podobnej specyfikacji jak ARK-2121, wyposażony w:

- 8 GB pamięci RAM,
- 120 GB dysk SSD,
- 4-rdzeniowy procesor Intel Celeron J1900,
- System operacyjny: Linux.

Ten komputer został użyty do klasyfikacji pojazdów oraz przetwarzania danych z pętli indukcyjnych.

2.20.3. Raspberry Pi Pico

Wykorzystanie: Klasyfikatory, przetwarzanie danych z pętli indukcyjnych.

Raspberry Pi Pico jest mikrokontrolerem opartym na układzie RP2040, który zawiera:

- Dwurdzeniowy procesor ARM Cortex-M0+ taktowany zegarem do 133 MHz,
- 264 KB pamięci RAM,
- Wsparcie dla języków programowania takich jak MicroPython i C/C++.

Ta platforma została wykorzystana do realizacji klasyfikatorów oraz przetwarzania danych z pętli indukcyjnych, gdzie niskie zużycie energii i kompaktowy rozmiar były kluczowe.

2.21. Podsumowanie części teoretycznej

W niniejszej części teoretycznej omówiono kluczowe koncepcje związane z systemami ważenia pojazdów w ruchu (WIM), które stanowią fundament dla dalszych rozważań i analiz w pracy. Przedstawione zagadnienia mają na celu zbudowanie bazy teoretycznej, umożliwiającej zrozumienie i interpretację wyników badań. Skupia się na różnych aspektach budowy i działania takich systemów, począwszy od konstrukcji stanowiska wagowego, a skończywszy na szczegółowym opisie różnych typów czujników oraz omówieniu metod przetwarzania danych.

2.21.1. Przegląd literatury

Przegląd literatury pozwolił na zidentyfikowanie istotnych prac naukowych oraz kierunków badań w dziedzinie systemów WIM. Szczególną uwagę poświęcono następującym obszarom:

- Kluczowe definicje i pojęcia związane z systemami WIM, w tym rodzaje stosowanych czujników, takich jak pętle indukcyjne, czujniki magnetyczne, piezoelektryczne i kwarcowe.
- Główne teorie i modele stosowane w analizie sygnałów z czujników WIM, w tym algorytmy przetwarzania sygnałów oraz techniki klasyfikacji pojazdów.
- Przegląd dotychczasowych badań empirycznych dotyczących dokładności systemów WIM i wpływu warunków zewnętrznych na wyniki pomiarów.

Analiza literatury umożliwiła identyfikację luk badawczych, które stały się punktem wyjścia do sformułowania problemu badawczego oraz celów niniejszej pracy.

2.21.2. Podstawy teoretyczne

W oparciu o przegląd literatury, opracowano ramy teoretyczne, które będą wykorzystywane w dalszej części pracy. Kluczowe elementy tych ram obejmują:

- Opis i charakterystykę systemów WIM, w tym zasadę działania różnych typów czujników oraz metody analizy sygnałów.
- Analizę czynników wpływających na dokładność pomiarów w systemach WIM, takich jak dynamika pojazdu, stan nawierzchni oraz warunki atmosferyczne.
- Przedstawienie zależności pomiędzy różnymi zmiennymi związanymi z funkcjonowaniem systemów WIM, w tym zależności pomiędzy rodzajem czujnika a jakością zebranych danych.

Teoretyczne ujęcie systemów WIM opiera się na założeniach wynikających z analizy sygnałów oraz teorii przetwarzania danych, co pozwala na sformułowanie hipotez badawczych oraz założeń metodologicznych.

2.21.3. Założenia badawcze

Na podstawie przedstawionych ram teoretycznych, sformułowano kluczowe założenia badawcze, które stanowią podstawę dla części empirycznej pracy. Zdefiniowane hipotezy odnoszą się do:

1. Odpowiednio dobrane i zaprojektowane algorytmy przetwarzania sygnałów z czujników mogą znacząco zwiększyć funkcjonalność stacji ważenia pojazdów w ruchu, bez konieczności istotnej rozbudowy infrastruktury fizycznej.
2. Zastosowanie odpowiednich algorytmów oraz oprogramowania do przetwarzania danych umożliwia uruchomienie stacji ważenia pojazdów w ruchu do celów administracyjnych.
3. Istnieją algorytmy przetwarzania sygnałów, które zastosowane w przypadku niestacjonarnych systemów ważenia pojazdów w ruchu (WIM) wykazują wysoką odporność na zmieniające się warunki operacyjne i środowiskowe.

Założenia teoretyczne i wynikające z nich hipotezy będą weryfikowane w oparciu o dane empiryczne zgromadzone w trakcie badań.

2.21.4. Wnioski

Podsumowując, część teoretyczna dostarcza niezbędnych narzędzi analitycznych oraz koncepcyjnych do zrozumienia i oceny systemów WIM. Stanowi fundament, na którym opiera się cała konstrukcja badawcza, a także wyznacza kierunki dalszych rozważań i analiz. W kolejnych rozdziałach zostaną przedstawione wyniki badań empirycznych oraz omówione w kontekście zaprezentowanych wcześniej teorii.

2.21.5. Przyszłe kierunki badań

Na podstawie przeglądu literatury oraz założeń teoretycznych, zidentyfikowano potencjalne obszary wymagające dalszych badań. Wśród nich można wymienić:

- Pogłębienie analiz dotyczących wpływu warunków zewnętrznych na dokładność systemów WIM.
- Weryfikację założeń teoretycznych w różnych kontekstach, takich jak różne warunki drogowe i rodzaje pojazdów.
- Rozwój nowych modeli przetwarzania sygnałów, uwzględniających zaawansowane techniki uczenia maszynowego.

3. Eksperymenty i wdrożenia

W tej części pracy przedstawiono opisy badań wykonanych, przetestowanych i przeanalizowanych na stacjach testowych zlokalizowanych na kampusach akademickich Uniwersytetu Bielsko-Bialskiego, Akademii Górniczo-Hutniczej oraz na stacjach wdrożeniowych pod ruchem, zlokalizowanych na drodze DK44.

Badania skupiały się na opracowaniu i testowaniu nowych algorytmów analizy i oceny danych dla niestacjonarnych systemów ważenia pojazdów w ruchu. Część eksperymentalna pracy opisuje przeprowadzone działania oraz uzyskane wyniki.

Przeprowadzone badania można podzielić na dwa główne obszary:

- badania dotyczące sygnałów z pętli indukcyjnych,
- badania dotyczące sygnałów z czujników wagowych.

Opracowane algorytmy zostały podzielone na następujące kategorie:

- algorytmy analizy danych do klasyfikacji pojazdów na podstawie sygnałów z pętli indukcyjnych,
- algorytmy analizy danych do rozpoznawania modelu i marki pojazdu na podstawie sygnałów z pętli indukcyjnych,
- algorytmy analizy danych z czujników wagowych do odczytu wagi pojazdu,
- algorytmy oceny danych ze stacji ważenia pojazdów w ruchu.

3.1. Stanowiska badawcze i wdrożeniowe

3.1.1. Opis stanowiska badawczego 1

Pierwsze stanowisko, na którym opracowywano oraz testowano algorytmy, znajduje się na Uniwersytecie Bielsko-Bialskim i było wykorzystywane w ramach przeprowadzanych testów.

3. Eksperymenty i wdrożenia

Stanowisko to jest wyposażone w tensometryczne czujniki wagowe (W1, W2). Sygnały z tych czujników są przetwarzane przez komputer wagowy iWIM. Widok jezdni z czujnikami przedstawiono na rys. 3.1, natomiast na rys. 3.2 zamieszczono schemat rozmieszczenia czujników wraz z podstawowymi wymiarami.

Stanowisko zlokalizowane na Uniwersytecie Bielsko-Bialskim posiada pewne cechy, które można zakwalifikować jako niekorzystne:

- Brak możliwości przejazdu z wyższymi prędkościami.
- Trudności w utrzymaniu stałej prędkości podczas przejazdu.
- Zły stan nawierzchni, co może wpływać na dokładność i powtarzalność pomiarów.
- Brak możliwości testowania większych pojazdów, takich jak ciężarówki czy zestawy z naczepą.

Mimo tych ograniczeń, stanowisko sprawdziło się bardzo dobrze w trakcie wstępnych badań i testów algorytmów.

3.1.2. Stanowisko wdrożeniowe 1

W ramach grantu badawczo-rozwojowego „*Intelligent Weigh-in-Motion System*” (nr RPSL.01.02.00-24-00A3/19) zostało przygotowane stanowisko, na którym testowano możliwości wdrożeniowe systemu i algorytmów na drodze DK44. Stanowisko zostało zbudowane za zgodą Generalnej Dyrekcji Dróg Krajowych i Autostrad (GDDKiA). Stacja została wyposażona w pętle indukcyjne oraz cztery belki tensometryczne. Do akwizycji danych użyto komputera wagowego iWIM, a do przetwarzania danych zastosowano komputer przemysłowy ARK-2121. Lokalizację stacji ważenia pojazdów w ruchu pokazano na rys. 3.3

Stanowisko charakteryzuje się dużym natężeniem ruchu, wynoszącym około 7000 pojazdów na dobę. Średnia prędkość przejazdu wynosi 50 km/h, jednak w zależności od pory dnia i nocy występuje duże zróżnicowanie zarówno w prędkościach, jak i typach pojazdów. Instalacja została sklasyfikowana w klasie dokładności B+(7) zgodnie z normą COST 323.


3.1.3. Stanowisko badawcze 2

Kolejnym stanowiskiem badawczym było stanowisko zlokalizowane na kampusie Akademii Górniczo-Hutniczej (AGH). Stanowisko to składa się wyłącznie z pętli indukcyjnych, zaprojektowanych według autorskiego projektu zespołu badawczego z Katedry Metrologii i Elektroniki Wydziału Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej

3.1. Stanowiska badawcze i wdrożeniowe



Rysunek 3.1. Rozmieszczenie czujników W1 i W2. Źródło: materiały firmy APM PRO



Rysunek 3.2. Schemat rozmieszczenia czujników (wymiały w mm). Źródło: materiały firmy APM PRO

3. Eksperymenty i wdrożenia



Rysunek 3.3. Lokalizacja stanowiska wdrożeniowego (współrzędne: 50°13'05.4"N 18°49'57.1"E). Źródło: Google Maps

AGH. Zastosowane pętle indukcyjne obejmują zarówno standardowe pętle szerokie, wykonane zgodnie ze standardem TLS 2012, o wymiarach 2 m × 1 m, jak i wąskie pętle indukcyjne o szerokości 3,2 m × 0,1 m. Schemat budowy stacji pomiarowej przedstawiono na rys. 3.4.


Dodatkową innowacją zaproponowaną przez zespół badawczy jest układ pomiarowy działający na wielu częstotliwościach oraz akwizycja zarówno części rzeczywistej, jak i urojonej składowej sygnału. W klasycznych układach zazwyczaj rejestruje się jedynie składową urojoną sygnału, co stanowi istotną różnicę w porównaniu do nowego rozwiązania.

Każdy przejazd przez stację generuje trzy przebiegi sygnału na różnych częstotliwościach: f_1 , f_2 i f_3 . Sygnały wzbudzające poszczególne pętle indukcyjne (IL) są nadawane na następujących częstotliwościach:

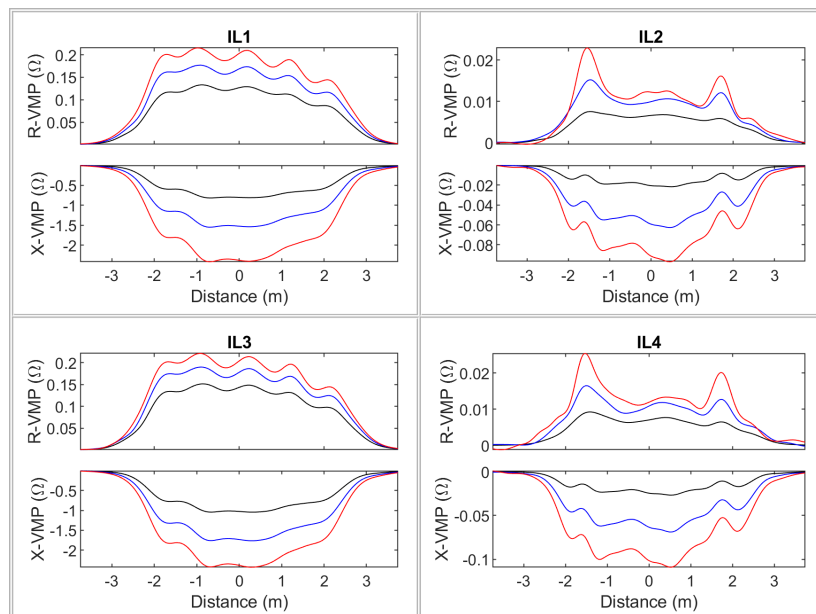
- IL1: 10, 18 i 27 kHz,
- IL2: 6, 15 i 22 kHz,
- IL3: 13, 21 i 28 kHz,
- IL4: 7, 16 i 24 kHz.

Przykładowe dane pozyskiwane na stacji przedstawiono na rys. 3.5.

3.1. Stanowiska badawcze i wdrożeniowe



Rysunek 3.4. Schemat budowy stacji z pętlami indukcyjnymi zaproponowanymi przez zespół z AGH. Źródło: materiały AGH



Rysunek 3.5. Sygnały z czterech pętli IL1, IL2, IL3, IL4 dla różnych częstotliwości oraz części rzeczywistej i urojonej dla przejazdu busa o masie do 3,5 tony. Źródło: materiały AGH

3.1.4. Stanowisko wdrożeniowe 2

Ostatnim stanowiskiem, z którego pobierane oraz analizowane były dane, zbudowano wspólnie z AGH w 2024 roku. Stanowisko skonfigurowane jest tak samo jak stanowisko zlokalizowane na kampusie akademickim – patrz podrozdział 3.1.3 – i połączone, za zgodą GDDKiA, z opisną wcześniej stacją WIM w tej samej lokalizacji na drodze DK44 – rys. 3.3. Dzięki temu można było rozszerzyć badania o kolejne klasy pojazdów oraz zestawzić wyniki z uzyskiwanymi z stacji WIM. Zdjęcie wybudowanej stacji zamieszczono na rys. 3.6.

3.2. Badania dotyczące sygnałów z pętli indukcyjnych

W badaniach dotyczących sygnałów z pętli indukcyjnych wykorzystano dwa układy akwizycji danych, opisane w rozdziale drugim. Pierwszym z nich był układ nazwany w niniejszej pracy „klasycznym”, który wykonuje akwizycję części urojonej sygnału uzyskanego na pojedynczej częstotliwości z jednej pętli indukcyjnej. Sygnał pozyskiwany z szerokiej pętli przedstawiono na rys. 3.7.

Drugim typem sygnałów analizowanych w ramach badań były sygnały z pojedynczej pętli, uzyskane jednak dla wielu częstotliwości nośnych, przy jednoczesnym zapisie zarówno części rzeczywistej, jak i urojonej sygnału. Podstawowy opis tych układów znajduje się w części teoretycznej w rozdziale 3.1.3. Przykładowe sygnały uzyskiwane z tej stacji przedstawiono na rys. 3.8.

Klasyfikacja pojazdów jest jedną z najczęściej wykorzystywanych informacji przez inżynierów ruchu drogowego czy inspekcje transportu drogowego. Służy ona przede wszystkim zrozumieniu jakie ograniczenia dotyczą danego pojazdu przejeżdżającego przez stację ważenia pojazdów w ruchu czy punkt klasyfikacyjny. Ta informacja wykorzystywana jest również do celów statystycznych do tworzenia modeli ruchu czy analizy dobowych obciążeń.


Na degradację dróg wpływa między innymi poruszanie się pojazdów przeciążonych lub o masie całkowitej przekraczającej dopuszczalne parametry na danej drodze [83, 89]. Kluczowym aspektem na obszarach miejskich staje się więc rozpoznanie struktury rodzajowej ruchu [88]. Pozwala to na przygotowanie odpowiedniej infrastruktury, dopasowanej do pojazdów poruszających się po danej drodze. Ważnym aspektem jest również wykluczanie z ruchu pojazdów przeciążonych [77]. Klasyfikacji pojazdów, na podstawie której określa się dopuszczalną masę całkowitą, pozwoli to określać strukturę rodzajową ruchu w ciągu całego roku, a nie tylko w trakcie obowiązkowych okresowych pomiarów ruchu.

3.2. Badania dotyczące sygnałów z pętli indukcyjnych

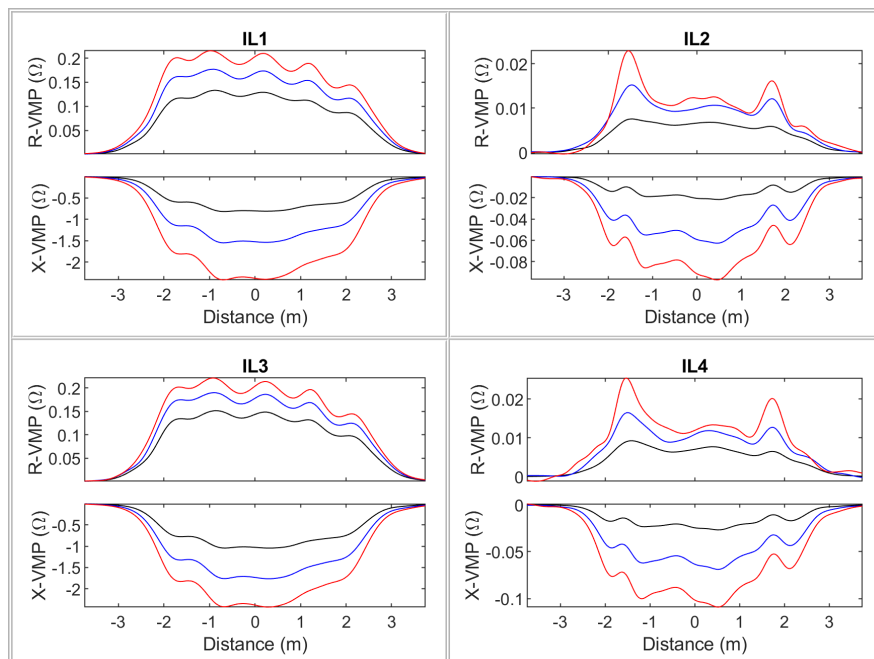


Rysunek 3.6. Stacja WIM + pętle indukcyjne według koncepcji zespołu badawczego z AGH. Źródło: materiały firmy APM PRO

3. Eksperymenty i wdrożenia



Rysunek 3.7. Sygnał z "klasycznego" układu akwizycji dla busa do 3,5 tony. Źródło: opracowanie własne



Rysunek 3.8. Sygnały z czterech pętli IL1, IL2, IL3, IL4 dla różnych częstotliwości oraz części rzeczywistej i urojonej dla przejazdu busa do 3,5 tony. Źródło: materiały AGH

3.2. Badania dotyczące sygnałów z pętli indukcyjnych

Istnieje wiele sposobów rozpoznawania kategorii pojazdu, między innymi na podstawie zdjęć z kamer, danych ze stacji ważenia pojazdu w ruchu, czy też na podstawie sygnału z pętli indukcyjnych. Klasyfikacja na podstawie obrazu z kamer sprawdza się jedynie w określonych warunkach pogodowych. Ze stacji *Weight In Motion* (WIM) otrzymujemy zestaw danych wystarczających do stworzenia klasyfikatora o bardzo wysokiej skuteczności [86]. Koszt takiej instalacji, stopień ingerencji w nawierzchnię drogi oraz wymagania dotyczące parametrów nawierzchni oraz podbudowy sprawiają, że stacje WIM nie są powszechnie stosowane. Do pełnego określenia struktury rodzajowej ruchu w mieście potrzebnych jest wiele klasyfikatorów, praktycznie na każdej z ulic. Zachodzi zatem potrzeba zastosowania systemu opartego na prostej, taniej oraz łatwej do instalacji architekturze, najlepiej wykorzystującego już istniejące rozwiązania.

System z zastosowaniem pętli indukcyjnych zakłada wykorzystanie już istniejącej infrastruktury, gdyż wiele miejskich skrzyżowań posiada sterowanie sygnalizacją świetlną opartą na wykrywaniu zbliżających się pojazdów przez pętle. Istnieje możliwość ich wykorzystania, pod warunkiem, że odpowiadają standardowi TLS. W trakcie przejazdu przez pętlę indukcyjną zamontowaną w nawierzchni drogi można zarejestrować profil magnetyczny pojazdu. Poniższe wykresy przedstawiają przykładowe profile dla różnych klas pojazdów.

Określamy dwa główne podziały pojazdów na klasy COST 323 [48] i TLS 8+1 [7]. W specyfikacji TLS 8+1 pojazdy dzielimy na: motocykle (10), samochody osobowe (7), samochody dostawcze do 3,5 t (11), samochody osobowe z przyczepami (2), samochody ciężarowe jednoosobowe (3), samochody ciężarowe z przyczepami (8), samochody ciężarowe z naczepami (9), autobusy (5). Prawidłowe, automatyczne rozpoznawanie klas pojazdu pozwoli na ocenę sposobu wykorzystywania danej drogi. Dokładny opis poszczególnych schematów klasyfikacji znajduje się w podrozdziale 2.19 niniejszej pracy. Ze względu na przepisy w Polsce powszechnie stosuje się schemat klasyfikacji TLS 8+1, w związku z czym ten schemat przyjęto jako docelowy tworząc poszczególne klasyfikatory.

Początkowy etap badań polegał na wstępnej analizie danych dostępnych z stacji ważenia pojazdów w ruchu, w tym przypadku z pętli indukcyjnych. W ramach projektu iWIM ('Intelligent weigh-in-motion system' no. RPSL.01.02.00-24-00A3/19) wytworzono układ akwizycji danych z pętli indukcyjnej, która znajduje się w drodze. Początkowo jednak część z sygnałów była obciążona dużymi błędami, tj. pojawiały się w odczytach zakłócenia od silnika, wzbudzenia z drugiej pętli i inne.

3.2.1. Automatyczna klasyfikacja pojazdów

Klasyfikacja pojazdów jest kluczowa dla inżynierii ruchu oraz inspekcji transportu drogowego, umożliwiając określenie ograniczeń jakie obowiązują pojazdy przejeżdżające przez stacje ważenia w ruchu oraz tworzenie modeli ruchu i analizę obciążeń drogowych. Właściwa klasyfikacja pomaga w zapobieganiu degradacji dróg spowodowanej przeciążonymi pojazdami [83, 89], a także w planowaniu infrastruktury dostosowanej do lokalnych warunków ruchu [77, 88].

Metody klasyfikacji pojazdów mogą opierać się na analizie zdjęć, danych z systemów WIM lub sygnałów z pętli indukcyjnych. Chociaż klasyfikacja na podstawie obrazów jest skuteczna jedynie w sprzyjających warunkach pogodowych, systemy WIM zapewniają wysoką dokładność, ale są kosztowne i trudne w instalacji [86]. Alternatywą jest wykorzystanie pętli indukcyjnych do rejestrowania profili magnetycznych pojazdów.

Pojazdy klasyfikuje się zgodnie z dwoma głównymi schematami: COST 323 [48] i TLS 8+1 [7], który obejmuje takie kategorie jak motocykle, samochody osobowe, dostawcze do 3,5 t, ciężarowe oraz autobusy. Automatyczna klasyfikacja pojazdów umożliwia ocenę struktury rodzajowej ruchu.


W ramach projektu iWIM opracowano układ akwizycji danych z pętli indukcyjnej. Początkowe testy wykazały jednak zakłócenia w sygnałach, które wymagały korekty przed dalszymi badaniami algorytmów klasyfikacyjnych. Przykłady występujących zakłóceń pokazano na rys. 3.9 oraz 3.10.

Po odpowiednim dostrojeniu układu, zakłócenia zostały wyeliminowane, a sygnały były odpowiednie do dalszych badań.


3.2.2. Estymacja długości pojazdu – podejście 1

Do stworzenia regresora przewidującego długość pojazdu wykorzystano wektor cech opisanego w podrozdziale 2.14.4 składający się ze 141 elementów, w tym wielu dodatkowych cech uzyskanych z analizy transformacyjnej. Przed przystąpieniem do budowy modelu, znormalizowano dane, tak aby średnia wartość wynosiła 0, a odchylenie standardowe 1. Okazało się, że normalizacja znacząco poprawiła wyniki w porównaniu do przypadków, gdy dane nie były normalizowane.

3.2. Badania dotyczące sygnałów z pętli indukcyjnych

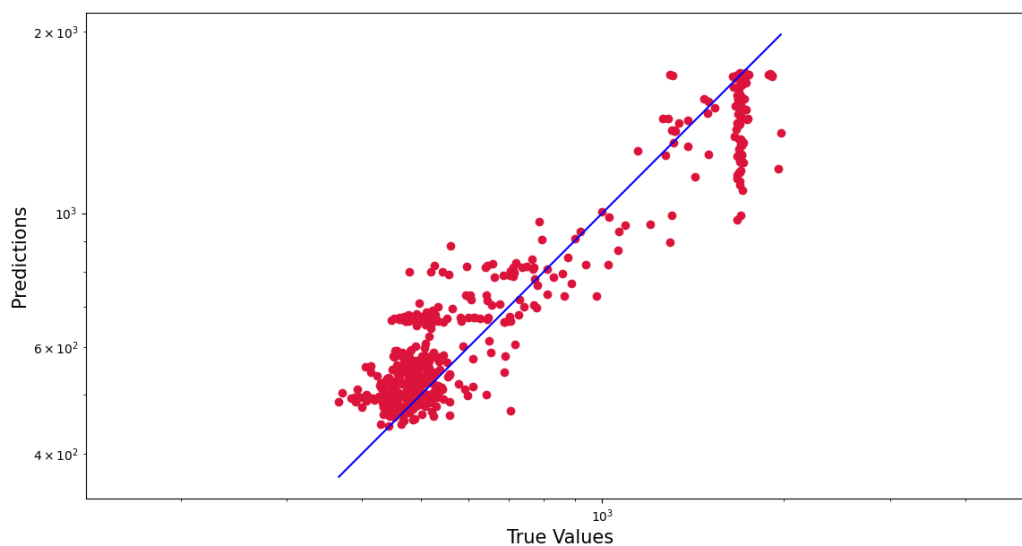


Rysunek 3.9. Błędny odczyt danych z pętli indukcyjnej. Źródło: opracowanie własne



Rysunek 3.10. Zaszumiony sygnał z pętli indukcyjnej. Źródło: opracowanie własne

3. Eksperymenty i wdrożenia




Rysunek 3.11. Porównanie wartości estymowanych przez regresor do wartości zmierzonych. Źródło: opracowanie własne

Następnie zastosowano analizę czynnikową opisaną w rozdziale 2.15, co umożliwiło identyfikację cech o największym wpływie na dokładność przewidywania długości pojazdu. Dodatkowo, analiza ta pozwoliła na redukcję złożoności obliczeniowej, co było istotne dla poprawy efektywności całego procesu.

Po przygotowaniu danych, przetestowano kilka algorytmów regresyjnych, aby wybrać ten, który osiągnie najwyższą precyzję. Przeanalizowano działanie regresora lasu losowego opisanego w Rozdziale 2.16, regresora drzewa decyzyjnego, klasyfikatora głosującego (który łączył regresor lasu losowego i regresję logistyczną), maszyny wektorów nośnych oraz regresji logistycznej. Spośród tych metod, regresor lasu losowego osiągnął najlepszą średnią dokładność na poziomie 85% w trakcie 10-krotnej walidacji krzyżowej. Wyniki pokazano na rys. 3.11.

Przeprowadzono test Shapiro-Wilka, aby ocenić normalność rozkładu uzyskanych wyników. Test wykazał, że statystyka wynosiła 0,99, a wartość p 0,36 (dla losowego zestawu danych, różnego od zbioru uczącego i testowego), co wskazuje na brak podstaw do odrzucenia hipotezy o normalności rozkładu danych. Analiza rozkładu normalnego ujawniła, że 95,5% oszacowanych wartości mieściło się w granicach $\pm 26\%$ od rzeczywistej długości co pokazano na rys. 3.12. Choć taka precyzja nie pozwala na dokładne określenie długości pojazdu, jest wystarczająca do klasyfikacji pojazdów w czterech przedziałach długości: krótki (3-5 metrów), średniej długości (7-9 metrów), długi (11-13 metrów) oraz bardzo długi (15-19 metrów).

3.2. Badania dotyczące sygnałów z pętli indukcyjnych



Rysunek 3.12. Procentowy rozkład odchylenia wartości estymowanej względem zmierzonej długości pojazdu. Źródło: opracowanie własne

3.2.3. Klasyfikator rozpoznający liczbę osi – podejście 1

W celu rozpoznania liczby osi pojazdu, zastosowano wektor cech zawierający 167 elementów, z których większość pochodziła z analizy transformacyjnej sygnałów opisanej w Rozdziale 2.14.4. Proces klasyfikacji rozpoczęto od standaryzacji wektora cech, co okazało się kluczowe dla uzyskania najlepszych wyników.

Spośród wielu testowanych algorytmów klasyfikacyjnych przedstawionych w Rozdziale 2.16, las losowy okazał się najskuteczniejszy, osiągając najlepszą precyzję w przewidywaniu liczby osi. W trakcie badań zrezygnowano z zastosowania analizy czynnikowej przedstawionej w Rozdziale 2.15 (takiej jak PCA, FA czy ICA), ponieważ nie przyniosła ona poprawy w wykrywaniu liczby osi.

Ostatecznie, klasyfikator oparty na losowym lesie osiągnął wyjątkowo wysoką dokładność, przekraczającą 99% w zestawie testowym, co potwierdza jego skuteczność w precyzyjnym rozpoznawaniu liczby osi pojazdów. Wyniki przedstawiono w tab.3.1.

3.2.4. Klasyfikacja pojazdów na podstawie sygnałów z pętli – podejście 1

W ramach badań przeprowadzonych na stacji zlokalizowanej przy drodze krajowej nr 44, przetworzono próbkę około 1000 pojazdów. Surowe sygnały zostały odsumione i poddane decymacji, a następnie wyekstrahowano zbiór cech, obejmujących miary statystyczne wektor szerzej został opisany w rozdziale 2.14.1, liczbę osi uzyskaną z klasyfikatora przedstawionego w rozdziale 3.2.3 oraz długość pojazdu wyznaczoną przez regresor przedstawiony w rozdziale

3. Eksperymenty i wdrożenia

Tabela 3.1. Dokładność klasyfikacji liczby osi pojazdów przy użyciu klasyfikatora opartego na losowym lesie

Liczba rzeczywistych osi	Dokładność klasyfikacji	Liczba próbek w zestawie testowym	Liczba błędnych klasyfikacji	Liczba próbek w zestawie uczącym
2	100%	14	0	30
3	100%	14	0	30
4	100%	14	0	30
5	100%	14	0	30

Tabela 3.2. Wyniki klasyfikacji pojazdów przy użyciu klasyfikatora głosującego

Rzeczywista klasa pojazdu	Dokładność klasyfikacji	Liczba próbek w zbiorze testowym	Liczba błędnie sklasyfikowanych	Liczba próbek w zbiorze uczącym
2	100%	30	0	63
3	98%	41	1	99
5	100%	44	0	96
7	100%	37	1	103
8	92%	24	2	63
9	91%	33	3	107
11	100%	42	0	148

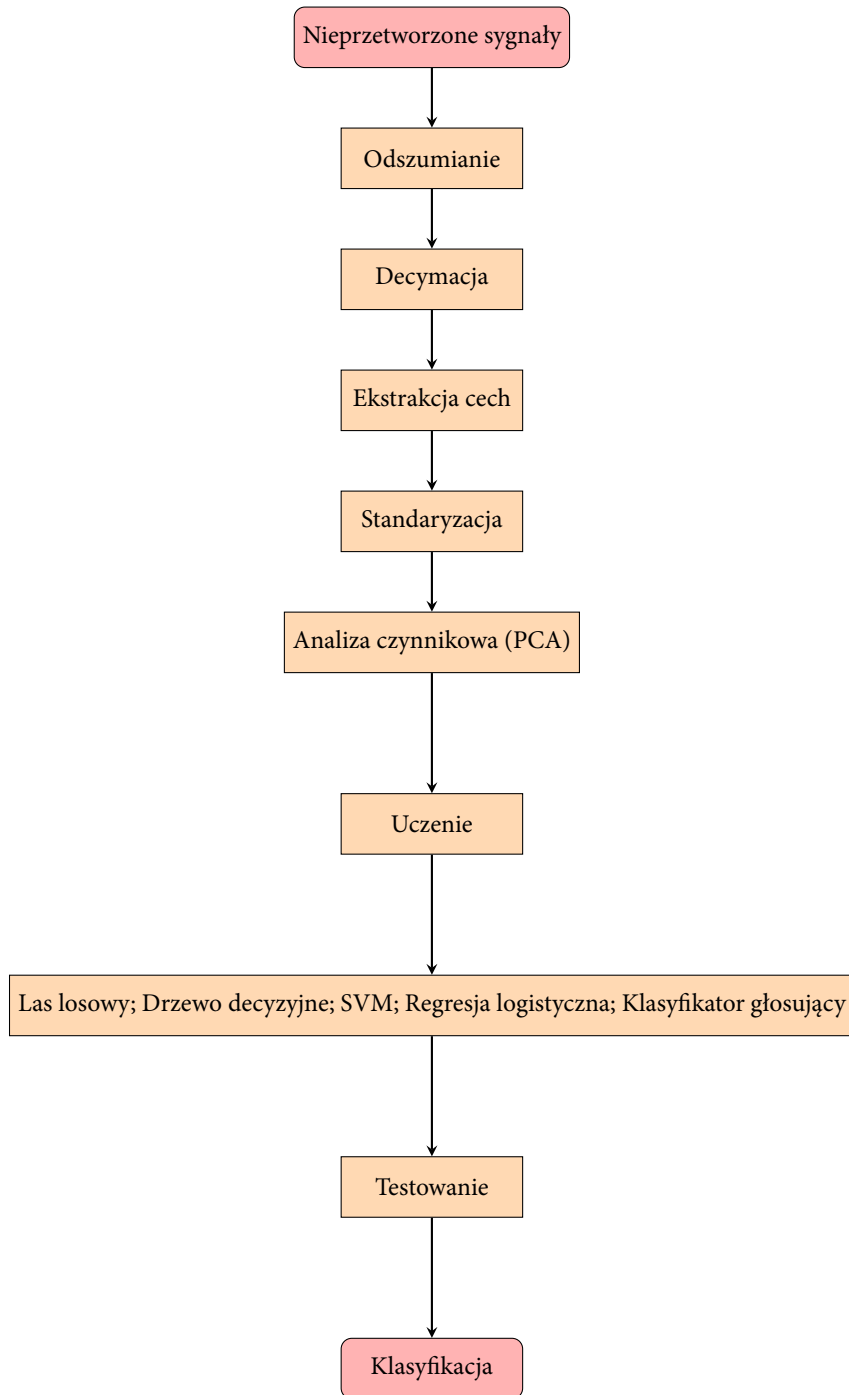
3.2.7. Po standaryzacji danych (średnia 0, odchylenie standardowe 1), przeprowadzono analizę czynnikową PCA szerzej przedstawioną w rozdziale 2.15, co pozwoliło na wyodrębnienie najważniejszych składowych wektora cech.

Przygotowane wektory cech zostały wykorzystane do treningu kilku klasyfikatorów: lasu losowego, drzewa decyzyjnego, maszyny wektorów nośnych (SVM), regresji logistycznej oraz klasyfikatora głosującego, składającego się z lasu losowego i regresji logistycznej. Schemat procesu treningu klasyfikatorów przedstawiono na rys. 3.13.

Wyniki testów wykazały, że klasyfikator głosujący osiągnął najwyższą dokładność klasyfikacji, wynoszącą średnio 94% w dziesięciokrotnej krosvalidacji. tab. 3.2 przedstawia szczegółowe wyniki dla poszczególnych klas pojazdów według schematu TLS 8+1.

Niższa dokładność w klasach 8 i 9 wynikała z dużego podobieństwa sygnałów i cech między tymi klasami. W dalszych badaniach planowane jest uzupełnienie wektora cech, aby poprawić rozróżnienie w tych klasach.

3.2. Badania dotyczące sygnałów z pętli indukcyjnych



Rysunek 3.13. Schemat procesu klasyfikacji pojazdów

Tabela 3.3. Wyniki klasyfikacji pojazdów przy użyciu klasyfikatora głosującego

Rzeczywista klasa pojazdu	Dokładność klasyfikacji	Liczba próbek w zbiorze testowym	Liczba błędnie sklasyfikowanych	Liczba próbek w zbiorze uczącym
2	97%	70	2	251
3	96%	55	2	251
5	100%	61	0	251
7	99%	72	1	251
8	100%	78	0	251
9	97%	66	2	251
10	100%	15	0	42
11	99%	67	1	251

3.2.5. Klasyfikacja pojazdów na podstawie sygnałów z pętli – podejście 2

W badaniach przeprowadzonych w 2021 roku rozszerzono zbiór danych uczących i testowych, osiągając łącznie około 2000 rekordów, co pozwoliło na uzyskanie ponad 200 próbek dla każdej klasy pojazdu. Upewniono się, że liczebność próbek w poszczególnych klasach była równomierna, co miało na celu zwiększenie dokładności klasyfikacji.

W porównaniu do wcześniejszych podejść, wektor cech został wzbogacony o lokalne maksima widma sygnału, uzyskane za pomocą szybkiej transformaty Fouriera (FFT) oraz transformaty świergotowej. W wyniku tego, łącznie z cechami statystycznymi i estymowanymi parametrami rzeczywistymi, wektor cech zawierał 64 elementy opisany w rozdziale 2.14.1. Znormalizowano dane, co zwiększyło skuteczność klasyfikacji, ustalając odchylenie standardowe na poziomie 1, a średnią wartość na 0.

Testowano różne algorytmy analizy czynnikowej, takie jak ICA, PCA i FA opisanych w rozdziale 2.15, jednak ich zastosowanie nie poprawiło wyników klasyfikacji, dlatego ostatecznie zrezygnowano z ich użycia. Podobnie jak w poprzednich badaniach, przetestowano kilka klasyfikatorów, w tym maszynę wektorów nośnych (SVM), regresję logistyczną, drzewo decyzyjne, losowy las oraz klasyfikator głosowania, który łączył regresję logistyczną z losowym lasem. Klasyfikatory zostały opisane w rozdziale 2.16.

Najwyższą dokładność, średnio 98% w dziesięciokrotnej walidacji krzyżowej, uzyskano przy użyciu klasyfikatora głosującego. Wyniki klasyfikacji dla poszczególnych klas pojazdów przedstawiono w tab.3.3.

Zauważono, że liczba próbek w kategorii 10 (motocykle) była stosunkowo niska w porównaniu z innymi kategoriami pojazdów. Ruch motocykli jest generalnie mniejszy, co sprawiło,

3.2. Badania dotyczące sygnałów z pętli indukcyjnych

że liczba zarejestrowanych próbek była ograniczona. Dodatkowo, część danych z przejazdów motocykli była niepełna, co wynikało z faktu, że pętla indukcyjna nie obejmuje całej szerokości pasa, co mogło prowadzić do niepełnej rejestracji sygnałów.

Najniższą dokładność klasyfikacji odnotowano dla klas 3 (ciężarówki), 9 (ciągniki siodłowe z naczepami) i 2 (samochody osobowe z przyczepą). Wynika to z dużego podobieństwa sygnałów uzyskiwanych z tych pojazdów, co sprawia, że ich rozróżnienie jest trudniejsze.

Pętle indukcyjne, wbudowane w nawierzchnię drogi, pełnią kluczową rolę w automatycznym systemie klasyfikacji pojazdów. Kiedy pojazd zbliża się do pętli, uruchamiany jest tor pomiarowy stanowiska wagowego, umożliwiający rejestrację profilu magnetycznego pojazdu. To zastosowanie nie ogranicza się jedynie do pomiarów wagowych; pętle indukcyjne odgrywają także istotną rolę w klasyfikacji pojazdów.

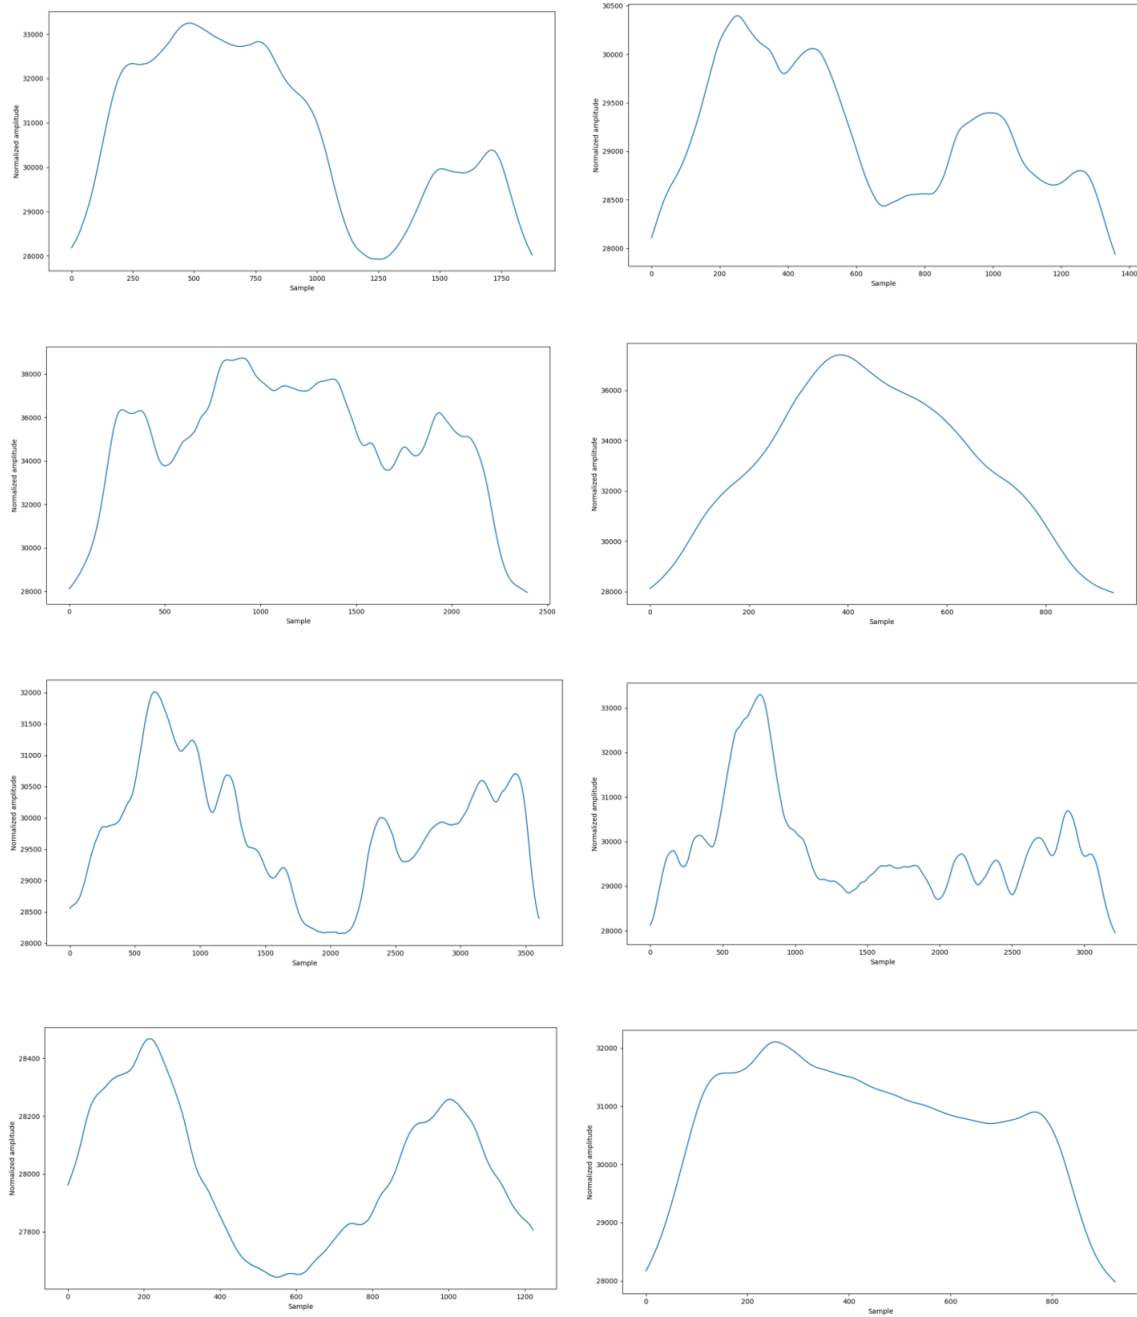
Standard TLS, który definiuje umiejscowienie, układ i rozmiar pętli na drodze, pozwala na budowę zunifikowanych stacji klasyfikacyjnych, gdzie pojazdy są klasyfikowane według kategorii, takich jak samochody ciężarowe z przyczepą, ciągniki siodłowe z naczepami, samochody osobowe, autobusy czy motocykle.

Dane z pętli indukcyjnych mogą być wykorzystane do klasyfikacji pojazdów, a na rynku dostępne są urządzenia, które, korzystając z informacji z dwóch pętli, potrafią precyzyjnie określić kategorię pojazdu. Przykładowe sygnały z pętli szerokiej przedstawiono na rys. 3.14 oraz w rozdziale 5.1.1.

Badania przeprowadzone w ramach „podejścia 1” oraz „podejścia 2” zaowocowały opracowaniem zaawansowanego klasyfikatora pojazdów. Korzystając z języka programowania Python, stworzono usługę sieciową, która przetwarza sygnały z pojedynczej pętli indukcyjnej. Program analizuje te sygnały i klasyfikuje pojazd w czasie rzeczywistym, a czas od wysłania danych do uzyskania odpowiedzi wynosi około 500 ms. Dzięki temu rozwiązanie to jest efektywne i może być z powodzeniem stosowane w środowisku przemysłowym.

Zaprojektowany klasyfikator został pomyślnie wdrożony w środowisku produkcyjnym podczas instalacji komputera wagowego iWIM na stacji przy drodze krajowej nr 44 w Mikołowie. Komputer ten, wyposażony w moduł odczytu danych z pętli indukcyjnej, przetwarza i klasyfikuje pojazdy, a wyniki są przechowywane w bazie danych. Dodatkowo, system gromadzi obrazy z kamer, co umożliwia weryfikację poprawności klasyfikacji. Obecnie system osiąga dokładność na poziomie około 96%. Na podstawie przeprowadzonych badań wykazano, że możliwe jest stworzenie klasyfikatora o wysokiej skuteczności, bazującego wyłącznie na jednej pętli indukcyjnej. Takie rozwiązanie ma potencjał zastąpienia bardziej złożonych systemów dwupętlowych lub tych wymagających dodatkowych czujników.

3. Eksperymenty i wdrożenia



Rysunek 3.14. Profile magnetyczne poszczególnych klas pojazdów według TLS 8+1: 2, 3, 5, 7, 8, 9, 10, 11. Źródło: opracowanie własne

3.2. Badania dotyczące sygnałów z pętli indukcyjnych

Tabela 3.4. Częstotliwości wzbudzenia dla różnych pętli

Częstotliwość wzbudzenia w kHz:	f1	f2	f3
#1: dla pierwszego standardowego sensora IL1	10	18	27
#3: dla drugiego standardowego sensora IL3	13	21	28
#2: dla pierwszego wąskiego sensora IL2	6	15	22
#4: dla drugiego wąskiego sensora IL4	7	16	24

Analizując profil magnetyczny pojazdu, system jest w stanie rozpoznać liczbę osi, długość oraz kategorię pojazdu. Dotychczasowe metody opierały się głównie na analizie obliczeniowej, nie uwzględniając głębszych powiązań między danymi, co jest możliwe dzięki algorytmom uczenia maszynowego. Dlatego autorzy zaproponowali nowe podejście oparte na tych zaawansowanych algorytmach.

W literaturze często sugeruje się zastosowanie klasyfikatorów korzystających z dwóch pętli indukcyjnych, jednak badania wykazały, że pojedyncza pętla, przy zastosowaniu zaproponowanej metody, może dać równie dobre wyniki. Takie podejście znacząco redukuje koszty i czas instalacji, co zwiększa jego potencjalne zastosowanie na szeroką skalę. Ponadto, wdrożenie tego systemu może wspomóc tworzenie map strukturalnych ruchu, co z kolei wpływa na lepsze zarządzanie infrastrukturą drogową, poprawę przepustowości oraz bezpieczeństwa na drogach.


Mimo obiecujących wyników, wykorzystanie pętli indukcyjnej jako źródła informacji o pojazdach wymaga dalszych badań. W trakcie testów zauważono, że kształt pętli może wpływać na sygnał, a co za tym idzie, na informacje uzyskiwane z tego sygnału. Dalsze badania mogą pomóc w optymalizacji kształtu i rozmieszczenia pętli, aby poprawić jakość danych oraz efektywność klasyfikacji.

3.2.6. Klasyfikacja pojazdów na podstawie sygnałów z pętli – podejście 3

W ramach kolejnego podejścia do klasyfikacji pojazdów, przeprowadzono badanie mające na celu ocenę wpływu zmiany geometrii pętli indukcyjnych oraz układu akwizycji danych na dokładność klasyfikacji. W tym celu zastosowano układ zaprojektowany przez grupę badawczą z Akademii Górniczo-Hutniczej (AGH), który, oprócz zapisu części urojonej sygnału, rejestruje także część rzeczywistą sygnału z pętli indukcyjnej. Na rys. 3.15 przedstawiono schemat budowy stacji pomiarowej.

Dodatkowo, układ akwizycji działa na trzech różnych częstotliwościach wzbudzenia, co pozwala na uzyskanie bardziej zróżnicowanych danych pomiarowych co przedstawiono w tabeli 3.4.

3. Eksperymenty i wdrożenia




Rysunek 3.15. Schemat budowy stacji na kampusie AGH. Źródło: materiały AGH


W rezultacie, z każdego przejazdu przez stację uzyskiwane są 24 przebiegi sygnałów, co znacznie zwiększa ilość danych dostępnych do analizy. Przykładowe sygnały przedstawiono na rys. 3.16. a pełną bazę można znaleźć w rozdziale 5.2

Dla porównania, standardowa pętla z klasycznym układem akwizycji dostarcza tylko jeden przebieg sygnału dla każdego pojazdu, przy jednej częstotliwości i rejestrując jedynie część urojonej sygnału co przedstawiono na rys. 3.17.

3.2. Badania dotyczące sygnałów z pętli indukcyjnych



Rysunek 3.16. Profile magnetyczne samochodu. R-VMP i X-VMP oznaczają rzeczywiste i urojone składowe impedancji oraz różne częstotliwości. Źródło: materiały AGH



Rysunek 3.17. Profil magnetyczny z klasycznego układu akwizycji oraz pętli. Źródło: opracowanie własne

W badaniu zidentyfikowano 6 klas pojazdów, z czego 4 odpowiadały klasom zdefiniowanym w standardzie TLS. Brak pełnego pokrycia standardu TLS wynikał z lokalizacji stacji badawczej na wewnętrznej drodze kampusu akademickiego. Zdefiniowane klasy pojazdów to: hulajnogi, rowery, motocykle, samochody osobowe, vany i ciężarówki. W każdej klasie zebrano po 400 próbek, które następnie podzielono w stosunku 70/30 na dane treningowe i testowe.

3. Eksperymenty i wdrożenia

Przetestowano 8 klasyfikatorów: regresję logistyczną, *Naive Bayes*, KNN, SVC, drzewo decyzyjne, losowy las, klasyfikator głoszący oraz sztuczną sieć neuronową które przedstawiono w rozdziale 2.16.

Wektor cech, które zostały użyte do uczenia i testowania, obejmował następujące parametry: maksymalna amplituda, średnia, odchylenie standardowe, kurtoza, skośność, wariancja, wartości maksymalne sygnału, średnia z wartości maksymalnych sygnału, obszar pod przebiegiem oraz długość magnetyczna przedstawiono go w rozdziale 2.14.2.

Zastosowano kilka konfiguracji tworząc wektory cech. Liczba cech w wektorach wahała się od 10 do 60, w zależności od zastosowanej konfiguracji. Cechy w liczbie 10 były pobierane dla każdego sygnału, w związku z czym dla każdej pojedynczej pętli mogliśmy uzyskać 60 cech, ponieważ z każdej pętli mamy sygnał w części rzeczywistej i urojonej na 3 częstotliwościach wzbudzenia. Różne konfiguracje wektorów cech przedstawiono w tab. 3.5.

Skupiono się na tworzeniu klasyfikatorów i analizie możliwości klasyfikacji w oparciu o jedną pętlę, ponieważ takie układy byłyby najprostsze w instalacji i używaniu oraz na rynku występuje bardzo mało tego typu urządzeń.

Tabela 3.5. Konfiguracje wektorów cech dla czujników IL

Typ cech	Konfiguracja				
	1	2	3	4	5
X-VMP przy wysokiej częstotliwości	•		•	•	•
R-VMP przy wysokiej częstotliwości		•	•	•	•
R-VMP i X-VMP przy średniej częstotliwości				•	•
R-VMP i X-VMP przy niskiej częstotliwości					•
Łączna liczba cech	10	10	20	40	60

Najlepsze wyniki (99,8%) uzyskano dla konfiguracji 3, która jest kombinacją cech obliczonych na podstawie R-VMP i X-VMP szerokiego czujnika IL3, przy użyciu klasyfikatora opartego na algorytmie RF. Ta konfiguracja, wraz z klasyfikatorem na wszystkich IL, dała bardzo dobre wyniki. Ranking algorytmów ML według średniej dokładności jest następujący: RF-1, ANN-2, VC-3, DT-4, NB-5, SVC-6, KNN-7, LR-8. Porównując średnie wartości dokładności dla wąskiego i szerokiego czujnika IL (tab. 3.6), wąski czujnik IL wykazuje większą dokładność o kilka procent.

Aby sprawdzić przenośność klasyfikatora, założono, że czujniki IL o tych samych wymiarach znajdują się w różnych lokalizacjach. Tabela 3.7 przedstawia wyniki dla różnych

3.2. Badania dotyczące sygnałów z pętli indukcyjnych

Tabela 3.6. Wartości dokładności poszczególnych klasyfikatorów dla różnych konfiguracji i czujników IL

Model ML	Konfiguracja	szeroka IL1 (%)	szeroka IL3 (%)	wąska IL2 (%)	wąska IL4 (%)
LR	1	68,9	64,4	95,2	96,2
LR	2	89,3	89,1	93,8	93,7
LR	3	87,3	87,9	96,1	97,3
LR	4	90,6	85,2	96,8	98,3
LR	5	90,4	87,4	97,3	98,4
NB	1	96,7	97,7	98,0	97,6
NB	2	96,8	96,8	93,4	92,4
NB	3	98,7	98,8	98,6	98,2
NB	4	98,5	98,7	98,3	98,0
NB	5	98,5	98,8	98,0	97,8
KNN	1	84,4	81,7	97,2	97,3
KNN	2	91,5	91,8	93,7	94,3
KNN	3	84,4	84,0	96,6	97,1
KNN	4	85,0	85,0	96,7	96,9
KNN	5	85,9	85,2	97,5	97,0
SVC	1	73,0	72,7	98,1	98,0
SVC	2	96,8	96,5	97,4	97,3
SVC	3	87,9	88,4	99,0	98,8
SVC	4	91,1	89,7	99,1	99,0
SVC	5	94,3	92,6	99,3	99,1
DT	1	98,0	98,3	98,5	98,2
DT	2	97,4	97,8	96,0	95,9
DT	3	99,1	99,4	98,7	97,9
DT	4	99,0	99,4	98,5	98,3
DT	5	98,9	98,9	98,6	98,5
RF	1	98,8	98,8	99,0	99,0
RF	2	98,5	98,6	97,5	97,9
RF	3	99,7	99,8	99,3	99,2
RF	4	99,7	99,7	99,2	99,3
RF	5	99,7	99,6	99,3	99,3
VC	1	98,3	98,5	98,5	99,0
VC	2	98,3	98,3	98,3	97,5
VC	3	99,2	99,1	99,1	99,2
VC	4	99,2	99,2	99,2	99,3
VC	5	99,2	99,3	99,3	99,1
ANN	1	97,2	97,8	99,2	99,0
ANN	2	99,0	99,3	98,5	97,9
ANN	3	99,3	99,3	99,6	99,6
ANN	4	99,3	99,2	99,3	99,0
ANN	5	99,2	99,4	99,3	99,6
Średnia					
Średnia	1	89,4	88,7	98,0	98,0
Średnia	2	96,0	96,0	96,0	95,9
Średnia	3	94,4	94,6	98,4	98,4
Średnia	4	95,3	94,5	98,4	98,5
Średnia	5	95,8	95,1	98,6	98,6

3. Eksperymenty i wdrożenia

źródeł treningowych i zestawów testowych przy użyciu klasyfikatora RF. W każdym przypadku szkolenie i testowanie odbywało się na pełnym zestawie danych, tj. 400 próbkach na klasę.

Tabela 3.7. Wyniki dla różnych źródeł treningowych i zestawów testowych przy użyciu klasyfikatora RF

Zbiór treningowy	Test: IL1	Test: IL2	Test: IL3	Test: IL4
IL1	-	-	99,6	-
IL2	-	-	-	99,1
IL3	99,8	-	-	-
IL4	-	99,7	-	-

Wyniki uzyskane przy przeniesieniu klasyfikatora trenowanego na danych z jednej pętli indukcyjnej do testowania na danych z innej pętli tego samego typu wykazały wysoką transferowalność utworzonych modeli klasyfikacyjnych. Jak przedstawiono w tabeli 3.7, dokładność klasyfikacji utrzymuje się na bardzo wysokim poziomie, co potwierdza skuteczność zastosowanej metody nawet w przypadku zmiany źródła danych testowych.

3.2.7. Estymator prędkości pojazdu – podejście 2

W tym podejściu długość magnetyczna pojazdu była obliczana na dwa różne sposoby. Pierwszy z nich opierał się na tzw. pułapce pętlowej. Dzięki znajomości odległości między pętlami (w tym przypadku 1,5 metra) oraz czasów najazdu na poszczególne pętle, można było obliczyć prędkość pojazdu, a następnie, znając długość sygnału, wyznaczyć długość magnetyczną pojazdu.

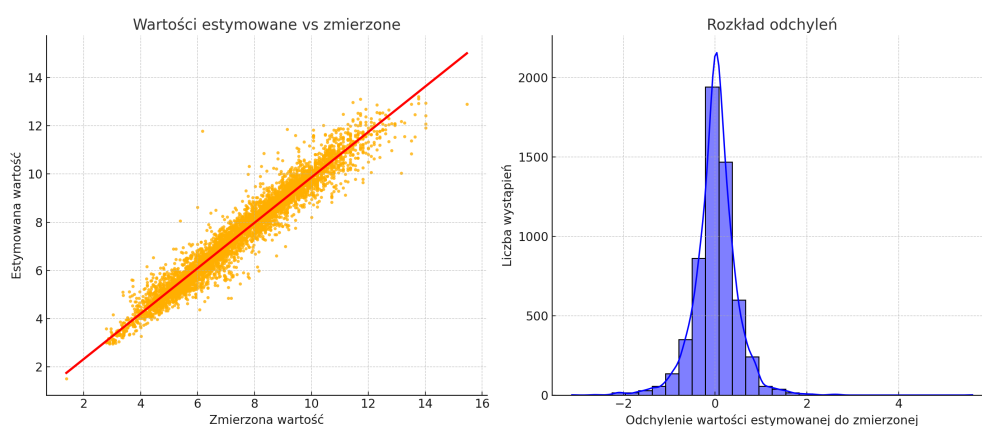
Drugie podejście polegało na stworzeniu regresora, bazującego na wektorze cech złożonym z 9 parametrów, jak zaproponowano w artykule [74]. Autorzy tego artykułu opracowali model statystyczny, który estymował prędkość pojazdu na podstawie wyodrębnionych cech i przygotowanego równania. W związku z tym postanowiono przeprowadzić badanie, w którym wykorzystano zaproponowany przez autorów wektor cech oraz modele uczenia maszynowego do estymacji prędkości pojazdu. Do stworzenia modeli regresora użyto następującego wektora składającego się z cech SR_2, SR_local, SR_global, Dur, Inv(dur), Max(dxdt(p)), Max(Num-Diff), Len, Aera opisane w podrozdziale 2.14.3. Przetestowano trzy modele regresji Random Forest Regressor, SVR (Support Vector Regression) oraz Linear Regression. Porównanie wyników trzech modeli przedstawiono w tabeli 3.8.

3.2. Badania dotyczące sygnałów z pętli indukcyjnych

Tabela 3.8. Porównanie wyników trzech modeli regresji oraz najlepszego modelu matematycznego z artykułu [74]

Model	R-squared
Random Forest	0,95
SVR	0,90
Linear Regression	0,61
Model matematyczny	0,92

Model Random Forest osiągnął najlepsze wyniki, charakteryzując się najniższymi wartościami błędów oraz najwyższym współczynnikiem R^2 , wynoszącym 0.95.



Rysunek 3.18. Rozkład odchyleń wartości estymowanych przy użyciu Random Forest Regressor do zmierzonych prędkości. Źródło: opracowanie własne

Do oceny modelu estymacji prędkości, w którym zastosowano regresor losowego lasu oraz przytoczony wektor cech, wykorzystano wskaźnik R-squared (R^2):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.1)$$

gdzie:

- y_i to rzeczywista wartość,
- \hat{y}_i to wartość przewidywana,
- \bar{y} to średnia wartość rzeczywista,
- n to liczba obserwacji.

R^2 pozwala ocenić, jak dobrze model jest dopasowany do danych. Wartość R^2 bliska 1 oznacza, że model jest dobrze dopasowany, natomiast wartość bliska 0 wskazuje, że model słabo wyjaśnia zmienność danych.

3. Eksperymenty i wdrożenia

W przypadku uzyskanego modelu wskaźnik R^2 wyniósł 0,95, co oznacza, że 95% zmienności w danych jest wyjaśniane przez model. Średni błąd modelu (RMSE) wyniósł 0,48 m/s, podczas gdy model przedstawiony w artykule [74] osiągał wartości błędów w przedziale od 0,7 do 2,4 m/s w zależności od klasy pojazdu. Warto zaznaczyć, że model zaproponowany przez autorów artykułu był modelem matematycznym, natomiast w tym badaniu, wykorzystując zaproponowany wektor cech i regresor losowego lasu, uzyskano znacznie lepsze wyniki. Na rys. 3.18 przedstawiono rozkład odchyleń wartości estymowanych od zmierzonych.

Wykorzystując prędkość estymowaną można na podstawie czasu trwania sygnału bezpośrednio obliczyć długość magnetyczną pojazdu. W związku z tym w wektorach cech służących do klasyfikacji pojazdów stosowano obie metody wyznaczania długości magnetycznej. W toku badań nie zauważono jednak wpływu metody wyznaczania długości na wyniki klasyfikacji.

3.3. Badania dotyczące sygnałów z czujników wagowych

3.3.1. Klasyfikacja na podstawie czujników wagowych - podejście 1


Czujniki wagowe stanowią kluczowy element konstrukcji stacji WIM. W ramach niniejszego badania wykorzystano tensometryczne czujniki nacisku, zamontowane prostopadle do kierunku ruchu pojazdów. Dwa czujniki zostały umieszczone w taki sposób, aby pokrywać całą szerokość pasa ruchu. Wygląd stacji pomiarowej pokazano na rys. 3.19.



Rysunek 3.19. Czujniki tensometryczne na stanowisku testowym UBB. Źródło: materiały firmy APM PRO

Każdy z czujników ma długość 1,5 m i szerokość 70 mm. W ramach badań wstępnych, dotyczących możliwości rozpoznawania pojazdów na podstawie sygnałów z czujników wagowych, zarejestrowano 22 przejazdy pojazdów typu SUV, kombi oraz bus do 3,5 tony.

3.3. Badania dotyczące sygnałów z czujników wagowych



Rysunek 3.20. Rozstaw osi wyznaczony metodami W1 i W2 dla poszczególnych pojazdów. Źródło: z artykułu [55]


Zbadano możliwości kategoryzowania pojazdów na podstawie wartości maksymalnej zarejestrowanego sygnału, czasu kontaktu opony z czujnikiem, związku między wartością maksymalną a czasem kontaktu oraz obszaru pod krzywą sygnału z czujnika wagowego. Nie stwierdzono jednak istotnych korelacji w tym zakresie.

Skupiono się również na ocenie możliwości wyznaczania parametrów pojazdu takich jak prędkość, liczba osi oraz rozstaw osi. Parametry te udało się wyznaczyć z dużą dokładnością – średni błąd pomiaru rozstawu osi nie przekroczył 3%, a liczba osi została określona bez żadnych błędów. Największy błąd dotyczył szacowania prędkości, który wynosił od 1% do 20% i malał wraz ze wzrostem prędkości.

Rozstaw osi został obliczony na dwa sposoby. W pierwszej metodzie (W1) wykorzystano prędkość obliczoną na podstawie przejazdu przez jeden czujnik, bazując na zależności między prędkością a czasem kontaktu opony z czujnikiem, opisaną za pomocą wielomianu, jak przedstawiono w pracy [55]. W drugiej metodzie (W2) użyto prędkości zmierzonej na podstawie czasu najazdu na poszczególne czujniki oraz odległości między nimi. Znając prędkość i czas przejazdu, obliczono odległość między osiami co przedstawiono na rys. 3.20.

Następnie oszacowano masę pojazdu na podstawie sygnałów z czujników wagowych, stosując dwie metody: WL1, opartą na maksymalnej wartości sygnału, oraz WL2, polegającą na wyznaczeniu obszaru pod krzywą sygnału. Metoda WL2 była dodatkowo podzielona na WL2a, wykorzystującą prędkość obliczoną z jednego czujnika, oraz WL2b, bazującą na prędkości

3. Eksperymenty i wdrożenia



Rysunek 3.21. Wartości nacisku wyznaczone metodami WL1, WL2a oraz WL2b. Źródło: z artykułu [55]

zmierzonej podczas przejazdu przez dwa czujniki. Najmniejszy rozrzut wartości uzyskano przy szacowaniu masy na podstawie wartości maksymalnej sygnału co zostało przedstawione na rys. 3.21.

Na podstawie przeprowadzonych badań wykazano, że istnieje możliwość rozróżniania pojazdów na podstawie sygnałów z czujników wagowych. Badania te są kontynuowane w celu opracowania klasyfikatora opartego o dane z tych czujników.


3.3.2. Klasyfikacja na podstawie czujników wagowych – podejście 2

Na podstawie danych z „podejścia 1” wybrano kluczowe parametry pojazdów, takie jak: długość pojazdu, odległość między osiami, masa poszczególnych osi oraz liczba osi. Próbki danych zostały zebrane dla 4 klas pojazdów według klasyfikacji TLS8+1, obejmujących kategorie: 7 (samochód osobowy), 11 (samochód dostawczy), 3 (samochód ciężarowy) oraz 5 (autobus). Dane zostały podzielone na zbiory uczący i testowy, z każdą kategorią reprezentowaną przez około 100 pojazdów w obu zbiorach.

Metody klasyfikacji

1. **Analiza dyskryminacyjna (DA):** w pierwszym podejściu zastosowano analizę dyskryminacyjną, wykorzystując długość pojazdu, odległość między osiami oraz liczbę osi jako zmienne wejściowe. Klasyfikacja osiągnęła dokładność na poziomie 89%, przy

3.3. Badania dotyczące sygnałów z czujników wagowych



Rysunek 3.22. Rozkład klas korzystając z kNN. Źródło: z artykułu [55]

czym najniższą skuteczność zaobserwowano w klasach ciężarówek (78%) oraz pojazdów dostawczych (86%).

2. **Algorytm k-najbliższych sąsiadów (kNN):** w kolejnym podejściu zastosowano algorytm kNN z parametrem $k = 5$. Ten algorytm znacząco poprawił dokładność klasyfikacji do 97%, w tym 96% skuteczności dla pojazdów dostawczych.

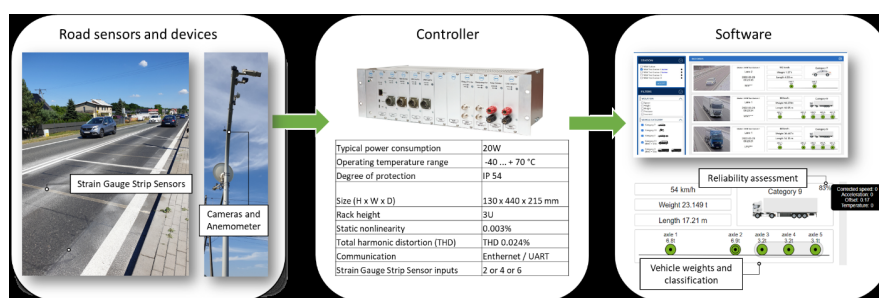
Wyniki klasyfikacji metodą DA wykazały największe błędy w przypisywaniu ciężarówek do klasy pojazdów dostawczych. Natomiast metoda kNN znacznie zredukowała te błędy, poprawiając dokładność klasyfikacji we wszystkich klasach pojazdów, a zwłaszcza w klasie pojazdów dostawczych. Na rys. 3.22 przedstawiono przypisanie rekordów do klas przez kNN.

Zastosowanie algorytmu kNN umożliwiło osiągnięcie wysokiej dokładności klasyfikacji, co jest szczególnie istotne dla automatycznych systemów kontroli, takich jak systemy WIM.

3.3.3. Ocena wiarygodności wyników ważenia pojazdów w ruchu

W nadchodzących latach badania nad systemami ważenia pojazdów w ruchu (WIM) będą prawdopodobnie skupiać się głównie na ich zastosowaniach w bezpośrednim egzekwowaniu przepisów. Taka potrzeba wynika z konieczności ochrony infrastruktury drogowej, podnoszenia poziomu bezpieczeństwa oraz z uwagi na kwestie ekologiczne. Wzmoczone prace

3. Eksperymenty i wdrożenia



Rysunek 3.23. Kluczowe elementy systemu iWIM. Źródło: z artykułu [58]

drogowe i zatory na drogach prowadzą do znacznego zanieczyszczenia środowiska, co można by ograniczyć poprzez efektywne zarządzanie przepływem ruchu drogowego.

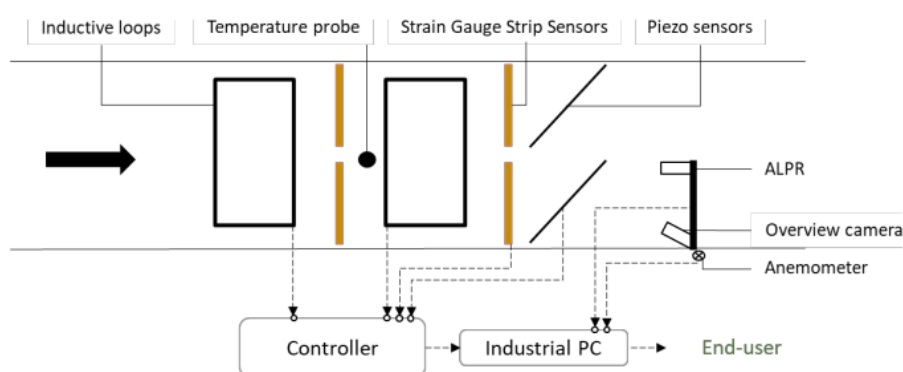
Jednym z największych wyzwań jest określenie poziomu zaufania do danych uzyskiwanych z systemów WIM. Niezawodność systemu w tym kontekście oznacza zdolność do precyzyjnego wykrywania przeciążonych pojazdów przy jednoczesnym minimalizowaniu liczby fałszywych alarmów w różnych warunkach i okresach eksploatacji. Kluczowe rezultaty projektu *Intelligent Weigh-in-Motion* (iWIM) obejmowały wdrożenie zaawansowanych rozwiązań sprzętowych i programowych, mających na celu zagwarantowanie, że tylko rzeczywiście przeciążone pojazdy będą podlegały sankcjom. Systemy WIM przeznaczone do bezpośredniego egzekwowania przepisów muszą cechować się bardzo wysoką dokładnością od momentu kalibracji, a także zapewniać przewidywalne wyniki w zmieniających się warunkach środowiskowych.

W wielu krajach systemy WIM są wykorzystywane do selekcji potencjalnie przeciążonych pojazdów. W 2011 roku Republika Czeska stała się pierwszym krajem, który wprowadził szczegółowe wymogi prawne i metrologiczne dotyczące certyfikacji i wykorzystania systemów HS-WIM (*High-Speed Weigh-in-Motion*) do bezpośredniego egzekwowania przepisów [31]. Obecnie kraje takie jak Brazylia [92], Francja [47] oraz Polska [41] prowadzą intensywne badania nad oceną możliwości wdrożenia systemów HS-WIM do bezpośredniego egzekwowania prawa.

Ważnym elementem projektu było opracowanie zarówno sprzętu, jak i oprogramowania, które mogłyby osiągnąć wysoki poziom automatyzacji i niezawodności. Automatyzacja stacji ważenia pojazdów w ruchu (HS-WIM) oferuje liczne korzyści, takie jak redukcja kosztów operacyjnych, minimalizacja zakłóceń w ruchu drogowym oraz możliwość nieprzerwanego przeprowadzania kontroli. Jednak pełna automatyzacja niesie ze sobą również wyzwania związane z zapewnieniem stabilności i niezawodności systemu, szczególnie w niekontrolowanych środowiskach, jakimi są drogi. Na rys. 3.23 przedstawiono kluczowe elementy systemu.

W ramach tego etapu projektu zaprojektowano system HS-WIM, który opiera się na

3.3. Badania dotyczące sygnałów z czujników wagowych



Rysunek 3.24. Schemat budowy stacji ważenia pojazdów w ruchu. Źródło: z artykułu [58]

czujnikach tensometrycznych do pomiaru obciążenia kół, czujnikach piezo-polimerowych zainstalowanych pod kątem 45° do pozycjonowania opon i ich śladów, pętlach indukcyjnych, stacji pogodowej, kamerze ANPR (*Automatic Number Plate Recognition*) oraz kamerze pogłądowej. Schemat budowy przedstawiono na rys. 3.24.


Wszystkie czujniki i kamery zostały podłączone do kontrolera iWIM, który korzysta z zaawansowanych procesorów FPGA (*Field-Programmable Gate Array*) umożliwiających przetwarzanie sygnałów w czasie rzeczywistym. Urządzenie to zaprojektowano zgodnie z wymaganiami standardu WELMEC [100]. Kontroler WIM komunikuje się z komputerem przemysłowym, na którym działa oprogramowanie przetwarzające dane oraz zapewniające interfejs użytkownika końcowego.

Wielkości pomiarowe rejestrowane przez system iWIM dla każdego pojazdu obejmują takie parametry jak: masa, długość, liczba osi, odległości między osiami, prędkość i przyspieszenie osi, czas trwania przejazdu, położenie i szerokość koła, rozstaw osi, prędkość i kierunek wiatru, a także temperaturę drogi. System został zaprojektowany do precyzyjnego ważenia pojazdów przy prędkościach do 129 km/h oraz nośności do 20 000 kg na oś.

Wybór tensometrycznych czujników nacisku w systemie iWIM był podyktowany ich zdolnością do utrzymania stabilności pomiarów przez cały rok, niezależnie od warunków zewnętrznych, takich jak temperatura. Wcześniejsze badania nad stabilnością różnych technologii czujników w instalacjach WIM wykazały, że przy odpowiednim podejściu do planowania, budowy, kalibracji i uruchomienia, możliwe jest uzyskanie powtarzalnych, stabilnych wyników w systemach WIM działających w środowiskach drogowych o dużych prędkościach [42].

Na rys. 3.25 przedstawiono wyniki długoterminowej stabilności systemów WIM z czujnikami tensometrycznymi, które zostały zaprezentowane przez [87].

3. Eksperymenty i wdrożenia



Rysunek 3.25. Masa całkowita ciągników siodłowych z naczepami na dwóch wybranych stacjach WIM. Źródło: z artykułu [58]

Badanie to oceniało długoterminową stabilność różnych lokalizacji i technologii HS-WIM. Systemy WIM z czujnikami tensometrycznymi wykazały pożądaną poziom stabilności, co można było zaobserwować na podstawie tzw. „histogramu dwóch szczytów GVW” techniki monitorowania masy całkowitej pojazdów 5-osioowych w czasie, stosowanej do zarządzania jakością danych WIM [82]. Wyrównane linie na wykresach przedstawiających różne miesiące w roku sugerują, że system utrzymywał stabilną wydajność przez cały okres badania.

Wyniki te zostały później potwierdzone przez Thompsona [95], który wskazał na wysoką zdolność czujników tensometrycznych do utrzymania kalibracji mimo zmieniających się warunków termicznych.

Czujniki i kamery są połączone z kontrolerem iWIM, który wykorzystuje zaawansowane procesory FPGA (*Field-Programmable Gate Array*) do przetwarzania sygnałów z różnych źródeł w czasie rzeczywistym. Kontroler umożliwia integrację sygnałów z tensometrycznych czujników obciążenia, pętli indukcyjnych i piezoelektrycznych czujników polimerowych w ramach jednego urządzenia, zapewniając jednocześnie przetwarzanie sygnałów analogowych na niskim poziomie. Sygnały z czujników tensometrycznych i piezo-polimerowych są próbkowane z częstotliwością 31250 Hz, a sygnały z pętli indukcyjnych z częstotliwością 3125 Hz. Dodatkowo, kontroler jest połączony z komputerem przemysłowym, który integruje pomiary WIM z danymi z czujników meteorologicznych i kamer.

Oprogramowanie systemu, działające na systemie Linux, jest zorganizowane jako rozproszony system mikrousług, które są skonteneryzowane i uruchamiane w środowisku Docker. Aplikacja gromadzi i przetwarza dane z czujników i kamer, zabezpieczając je przed utratą w wyniku chwilowego braku łączności, dzięki lokalnej archiwizacji i możliwości automatycznego przesyłania danych na zewnętrzny serwer. Oprogramowanie monitoruje działanie systemu, rejestrując dane w plikach dziennika, które zawierają informacje o kompletności danych i wskaźnikach oceny wiarygodności pomiarów. Monitorowane są także stan drzwi

3.3. Badania dotyczące sygnałów z czujników wagowych

szafy elektrycznej oraz poziom napięcia zasilającego, co pozwala na bieżące aktualizowanie stanu pracy stacji i generowanie alarmów.

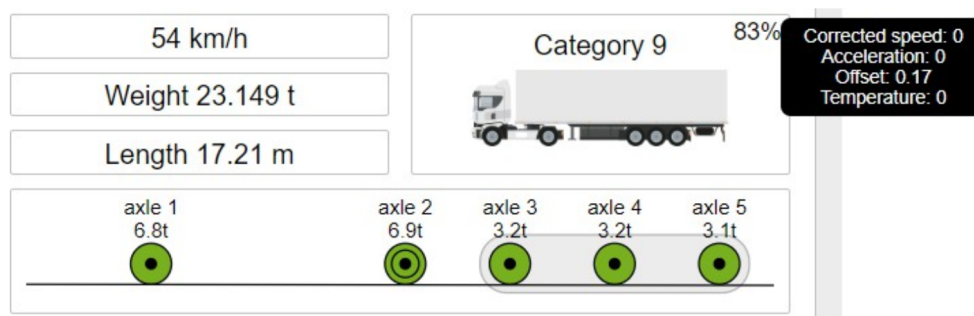
Jednym z kluczowych wyzwań projektu było opracowanie algorytmu przetwarzania danych WIM, który w czasie rzeczywistym ocenia wiarygodność każdego pomiaru. Oprócz stabilnych technologii pomiarowych, projekt obejmował stworzenie zaawansowanego algorytmu, który przypisuje współczynnik niezawodności dla każdego rekordu. Wskaźnik ten, oparty na logice rozmytej, ocenia wiele zmiennych, takich jak trajektoria ruchu pojazdu, stan nawierzchni i warunki pogodowe.

Algorytm oceny niezawodności uwzględnia zmienne, które mogą wpływać na dokładność pomiaru obciążenia dynamicznego, takie jak:

1. Prędkość pojazdu, uwzględniając wartość i kierunek prędkości wiatru.
2. Przyspieszenie pojazdu.
3. Przesunięcie punktu styku koła z czujnikiem.
4. Temperatura nawierzchni drogi.

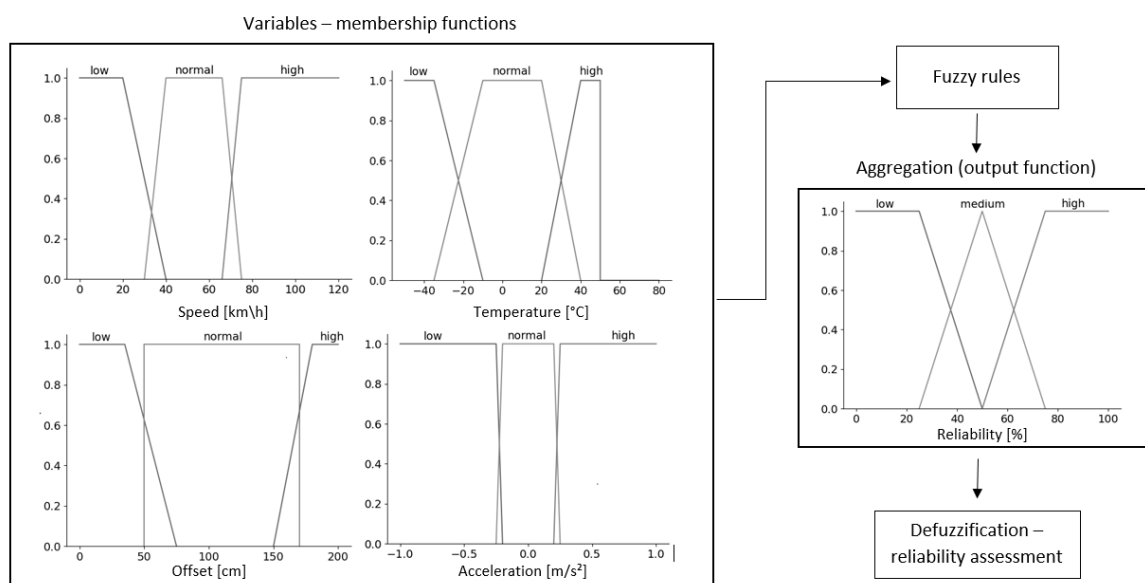
Badania eksperymentalne, przeprowadzone z udziałem pojazdów testowych o znanej masie, które przejeżdżały przez stację HS-WIM w różnych warunkach, wykazały, że te czynniki są kluczowe dla oceny wiarygodności pomiarów. Szczegółowe informacje na temat wpływu tych wskaźników są przedstawione w pracy [12].

System wskazuje, na ile pomiar w każdym rekordzie może być niedokładny, oraz identyfikuje czynniki mające największy wpływ na tę niedokładność. Użytkownik końcowy otrzymuje zarówno ogólny wynik procentowy, określający poziom ufności całego pomiaru, jak i indywidualne wyniki dla każdej zmiennej wpływającej na dokładność pomiaru. Przykład prezentacji wyników działania algorytmu pokazano na rys. 3.26.



Rysunek 3.26. Prezentacja oceny poziomu ufności pomiarów. Źródło: materiały firmy APM PRO

3. Eksperymenty i wdrożenia



Rysunek 3.27. Algorytm logiki rozmytej do oceny wiarygodności pomiaru. Źródło: z artykułu [58]

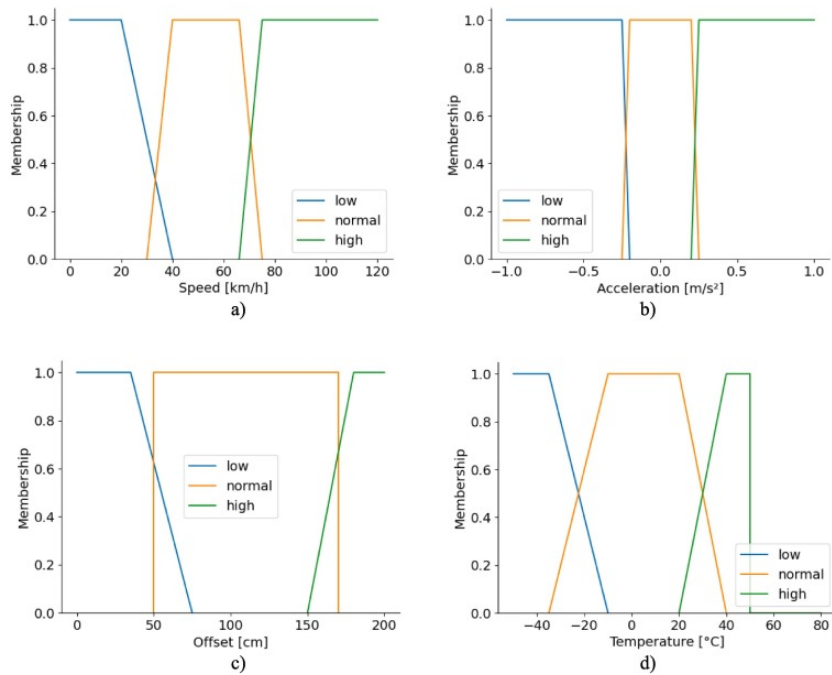
W celu automatyzacji procesu oceny wiarygodności pomiaru, wprowadzono logikę rozmytą. Zbiory rozmyte są idealnym rozwiązaniem w tym kontekście, ponieważ radzą sobie ze złożonymi i niejednoznacznymi pojęciami, które trudno zdefiniować przy użyciu tradycyjnych metod. Zastosowany algorytm został przedstawiony na rys. 3.27 blok *Fuzzy rules* został przybliżony na rys. 3.28. Ogólny opis działania logiki rozmytej znajduje się w rozdziale 2.18.

Dla każdego czynnika, który może wpływać na wiarygodność pomiarów, system ocenia, jak dobrze odpowiada on zdefiniowanym funkcjom przynależności. Zamiast ścisłych reguł, logika rozmyta umożliwia pewne nakładanie się opisów, co pozwala na bardziej zniuansowaną i elastyczną analizę. W ocenie każdego czynnika uwzględniane są trzy funkcje przynależności:

1. Sprawdzenie, czy wartość parametru mieści się w zakresie wartości uznawanych za normalne dla danej lokalizacji i typu pojazdu.
2. Sprawdzenie, czy parametr jest niższy od wartości uznawanych za normalne.
3. Sprawdzenie, czy parametr przekracza wartości uznawane za normalne.

Algorytm najpierw zmienia zarejestrowane wartości do postaci, która może być przetwarzana przez system, przypisując stopień przynależności do każdego z trzech zdefiniowanych zestawów. Następnie, system wykorzystuje reguły rozmyte do obliczenia poziomu ufności (niskiego, średniego lub wysokiego) dla analizowanego parametru. System przetwarza reguły wnioskowania, agregując dane z miar ufności dla każdego czynnika.

3.3. Badania dotyczące sygnałów z czujników wagowych



Rysunek 3.28. Reguły logiki rozmytej (Fuzzy rules)
. Źródło: z artykułu [12]


Wynikowa wartość liczbowa, uzyskana za pomocą logiki rozmytej, system przekształca w ostateczną ocenę możliwej dokładności pomiaru, co pozwala na podejmowanie decyzji dotyczących wiarygodności zgromadzonych danych.

Na wykresie rys. 3.29 przedstawiono przykłady zarejestrowanych przebiegów sygnałów, połączonych w okno czasowe dla pojedynczego przejazdu pojazdu 5-osowego. Pozwala to na identyfikację kluczowych punktów i cech między sygnałami pochodzącymi z różnych czujników. Nowe algorytmy wprowadzone w systemie rejestracji danych zwiększają funkcjonalność dotychczas stosowanych stacji ważenia pojazdów w ruchu (WIM). Wprowadzenie tych funkcji wymagało opracowania i przetestowania metod określania trajektorii pojazdu, szerokości opony oraz wykrywania podwójnych kół.

Ocena poprawności przejazdu

Aby ocenić poprawność przejazdu pojazdu przez stację WIM, konieczne jest precyzyjne określenie punktu kontaktu między oponą a czujnikami. Procedura ta obejmuje analizę sygnałów z czujników nacisku, które są zamontowane prostopadle do osi drogi, oraz czujników piezoelektrycznych umieszczonych po przekątnej.

3. Eksperymenty i wdrożenia



Rysunek 3.29. Sygnały agregowane przez komputer wagowy iWIM, zsynchronizowane w jednym oknie czasowym. Źródło: z artykułu [54]

Procedura oceny trajektorii:

1. **Określenie prędkości przejazdu:** prędkość każdej osi pojazdu jest obliczana na podstawie sygnałów z czujników nacisku.
2. **Obliczanie przyspieszenia:** na tej podstawie określa się przyspieszenie pojazdu podczas przejazdu przez stację.
3. **Analiza maksymalnych amplitud:** oblicza się przedział czasowy, w którym występują maksymalne amplitudy sygnału z czujników nacisku i piezoelektrycznych.
4. **Wyznaczenie punktu kontaktu:** poprzez obliczenie odległości pokonanej przez koło między czujnikami, można określić punkt kontaktu opony z czujnikiem piezoelektrycznym.
5. **Ocena trajektorii:** zmiany w trajektorii pojazdu są widoczne poprzez znaczną różnicę w punktach kontaktu między przednimi a tylnymi kołami, szczególnie w pojazdach 5-osiowych.

Określanie Szerokości Opony

Szerokość opony jest określana na podstawie sygnału z czujnika piezoelektrycznego. Proces ten obejmuje:

1. **Czas trwania impulsu:** określenie czasu trwania impulsu sygnału generowanego podczas przejazdu koła przez czujnik.

3.3. Badania dotyczące sygnałów z czujników wagowych

2. **Prędkość prostopadła:** obliczenie składowej prędkości prostopadłej do osi drogi w punkcie kontaktu opony z czujnikiem.
3. **Wyznaczenie szerokości opony:** szerokość opony odpowiada odległości, którą koło może pokonać z uzyskaną prędkością prostopadłą w czasie trwania impulsu.

Wykrywanie podwójnych kół

Algorytm wykrywania podwójnych kół korzysta z dwóch metod: porównania pokonanych odległości i analizy przedziałów czasowych.

Metoda porównania odległości:

1. **Analiza luk między osiami:** porównuje się luki z minimalnym rozstawem osi. Jeśli są one mniejsze niż minimalna wartość, zakłada się, że sygnał pochodzi z podwójnego koła.

Metoda porównania przedziałów czasowych:

1. **Analiza impulsów:** porównuje się czas trwania impulsu z czujników nacisku z czasem trwania impulsu z czujników piezoelektrycznych. Dłuższy impuls z czujnika piezoelektrycznego sugeruje podwójne koło.

Algorytm oceny wiarygodności

Algorytm oceny wiarygodności identyfikuje kluczowe czynniki wpływające na dokładność pomiaru, takie jak prędkość pojazdu, dynamika ruchu, trajektoria oraz warunki zewnętrzne (np. temperatura nawierzchni lub prędkość i kierunek wiatru). Algorytm umożliwia ocenę poprawności procesu ważenia zarówno pod kątem poszczególnych czynników, jak i poprzez określenie łącznego wskaźnika wpływu na dokładność pomiaru.

Każdy czynnik jest analizowany, a wyniki są przedstawiane użytkownikowi jako wskaźniki procentowe, które odzwierciedlają poziom ufności w dokładność pomiarów.

Wdrożenie

Algorytm określania ufności został wdrożony na stanowisku WIM zainstalowanym na drodze DK44 w Mikołowie - Śmiłowicach. W okresie od 29.09.2021 do 28.02.2022 zarejestrowano

3. Eksperymenty i wdrożenia

tam ponad 150 000 pojazdów ciężkich (tj. powyżej 3,5 tony). Wyniki z tej lokalizacji potwierdziły wykonalność i gotowość proponowanego systemu do bezpośredniego mandatowania. Widok poglądowy oraz lokalizację stacji przedstawiono na rys. 3.30



Rysunek 3.30. Wdrożenie systemu iWIM. Źródło: z artykułu [58]

Przed zainstalowaniem sprzętu WIM dokonano oceny stanu terenu, na podstawie której stwierdzono, że nawierzchnia w obszarze stacji jest odpowiednia dla warunków klasy I, zgodnie ze specyfikacjami COST323. Po zainstalowaniu czujników tensometrycznych przeprowadzono testy kalibracyjne w celu oceny dokładności systemu, a wyniki przedstawiono w tabeli 3.9. Metoda oceny dokładności COST323 uwzględnia trzy obiektywne zmienne: liczbę przebiegów (n), średnie błędy (m) i odchylenie standardowe błędów (s).

Tabela 3.9. Ocena dokładności stacji ważenia pojazdów w ruchu

Pojazd	Rodzaj pomiaru	n	m	s	Klasa dokładności
2-osie	GVW	12	0,57%	0,97%	A(5)
	Grupa osi	-	-	-	-
	Pojedyncze osie	28	-0,61%	3,56%	B+(7)
3-osie	GVW	14	0,66%	0,79%	A(5)
	Grupa osi	14	1,34%	0,99%	A(5)
	Pojedyncze osie	14	0,66%	0,79%	A(5)
5-osie	GVW	14	0,22%	0,76%	A(5)
	Grupa osi	14	0,94%	0,84%	A(5)
	Pojedyncze osie	28	-0,99%	2,25%	A(5)


Po regularnej kalibracji przeprowadzono badanie eksperymentalne, w którym wykorzystano pojazdy testowe o znanej masie, przejeżdżające przez HS-WIM w różnych warunkach,

3.3. Badania dotyczące sygnałów z czujników wagowych

takich jak różne parametry środowiskowe, dynamika ruchu i trajektorie jazdy. Badanie obejmowało pojazdy 2-osiowe, 3-osiowe i 5-osiowe o znanej masie. Całkowita masa pojazdów użytych w badaniu wahała się od 18 do 38 ton, a łącznie zebrano ponad 360 rekordów.

Na podstawie oceny zidentyfikowano zakresy błędów masy całkowitej i nacisku osi dla poszczególnych wyizolowanych parametrów, takich jak skorygowana prędkość, przyspieszenie, przesunięcie i temperatura. Analiza zebranych danych wykazała, że izolowane efekty parametrów związanych z trajektorią pojazdu i dynamiką ruchu miały największy wpływ na ogólną niepewność pomiaru.

Do badań wykorzystano 360 rekordów pojazdów do analizy wartości normatywnych oraz ponad 150 000 ciężkich pojazdów (tj. powyżej 3,5 tony) zarejestrowanych w okresie od 29.09.2021 r. do 28.02.2022 r. Pierwszym krokiem w procesie analizy danych było zrozumienie, które kategorie pojazdów były najbardziej istotne pod względem potencjalnych przeciążeń. Uzyskane informacje pozwoliły na analizę zachowania algorytmu niezawodności w kontekście tych często przeciążonych kategorii pojazdów. Poniższy wykres ilustruje, jak naruszenia przeciążenia zostały rozłożone na różne kategorie pojazdów zaobserwowane w tej lokalizacji.



Rysunek 3.31. Naruszenia w podziale na klasy pojazdów. Źródło: z artykułu [58]

W tym konkretnym miejscu najistotniejsze kategorie pojazdów pod względem naruszeń przeciążenia to kategoria 11 (samochody dostawcze) i kategoria 9 (przegubowe ciężarówki z 4 do 6 osiami) co przedstawiono na rys. 3.31. Stosując algorytm niezawodności w odniesieniu do tych konkretnych klas pojazdów, średni współczynnik niezawodności wynosił 85,63% i 78,69%, co wskazuje, że pojazdy te mają zwykle odpowiednią charakterystykę dla bardzo dokładnych pomiarów dynamicznych. Ogólnie rzecz biorąc, algorytm niezawodności okazał się działać prawidłowo dla wszystkich kategorii pojazdów.


Po dalszej analizie danych z wdrożenia pilotażowego okazało się, że pozycja (przesunięcie) przejazdu pojazdu miała największe prawdopodobieństwo spowodowania nieprawidłowej wartości pojedynczego parametru, wpływając na 40% przejazdów. Drugim parametrem, dla

3. Eksperymenty i wdrożenia

którego najczęściej rejestrowano wartości odbiegające od normy, była skorygowana prędkość – ponad 20% przejazdów miało skorygowaną wartość prędkości, która przekraczała to, co system rozumiał jako optymalny (normatywny).

Na podstawie interpretacji danych z badań eksperymentalnych i obserwacji rzeczywistego ruchu drogowego opracowano system wnioskowania. System uznaje poziom wiarygodności poniżej 50% za znaczące prawdopodobieństwo błędu pomiaru. W tym kontekście około 22% pomiarów zarejestrowanych na miejscu miało szansę wykazać niższą dokładność, a zatem można je było prawdopodobnie odrzucić w celu zastosowania kar w aplikacji bezpośredniego egzekwowania HS-WIM.

SHAP (*SH*apley *AD*ditive *EX*planations) [68] [67] to popularne, niezależne od modelu podejście do wyjaśniania wyników dowolnego modelu uczenia maszynowego. Wartości SHAP zapewniają wyjaśnienie wkładu każdej cechy w ostateczną prognozę. Korzystając z wykresów SHAP, można przeanalizować, jak często niektóre pomiary z nieprawidłowymi wartościami występowały razem i jak wpływały one na wiarygodność całego pomiaru. Pomaga to zrozumieć, które parametry są najważniejsze w zmniejszaniu dokładności pomiaru. W tym przypadku analiza SHAP została przeprowadzona na podstawie 10000 rekordów danych z lokalizacji DK44 HS-WIM.



Rysunek 3.32. Analiza SHAP algorytmu. Źródło: z artykułu [58]

Na rys. 3.32 przedstawiono wyniki analizy SHAP dla algorytmu. Każda cecha na wykresie SHAP jest reprezentowana przez poziomy pasek, a długość i kolor paska reprezentują wpływ tej cechy na ostateczną prognozę. Niebieski pasek oznacza, że cecha obniża prognozę (w kierunku ujemnego końca skali prognozy), podczas gdy czerwony pasek oznacza, że podwyższa prognozę

3.3. Badania dotyczące sygnałów z czujników wagowych

(w kierunku dodatniego końca skali prognozy). Długość paska reprezentuje siłę wpływu cechy na prognozę.

Na podstawie interpretacji wykresu SHAP można zauważyć, że w tym konkretnym miejscu przesunięcie może odgrywać ważniejszą rolę w zmniejszaniu wiarygodności pomiarów dynamicznych, podczas gdy temperatura wykazuje nieznaczny wpływ. Rozumie się, że wybór sprzętu pomiarowego i lokalizacji WIM przyczyniły się do utrzymania wysokiej jakości zarejestrowanych sygnałów w szerokim zakresie temperatur.

Wnioski


- **Największe wyzwanie związane z HS-WIM.** Kluczowym wyzwaniem przy wdrożeniu systemu HS-WIM do bezpośredniego egzekwowania przepisów jest zapewnienie, że żaden pojazd/kierowca nie zostanie niesłusznie ukarany, jeśli działa zgodnie z przepisami.
- **Znaczenie sprzętu i czujników.** Chociaż wybór odpowiednich czujników i sprzętu jest istotny, sam w sobie nie wystarczy, aby zagwarantować dokładne pomiary we wszystkich przypadkach przejazdu pojazdu i uniknąć pomyłek.
- **Różnorodność wiarygodności danych.** Systemy HS-WIM gromadzą dane ciągle, ale ich wiarygodność może różnić się w zależności od czynników, które nie są kontrolowane przez technologię pomiarową.
- **Kalibracja i niepewność pomiarów.** Kalibracja zapewnia dokładne pomiary w standardowych warunkach, jednak niepewność może wzrosnąć, gdy warunki odbiegają od tych norm.
- **Wpływ warunków zewnętrznych i dynamiki pojazdu.** Oczekiwano, że na wiarygodność pomiarów wpłyną dwie grupy parametrów: warunki zewnętrzne (jak wiatr i temperatura) oraz dynamika pojazdu (jak prędkość i lokalizacja styku opony z czujnikiem). Testy terenowe wykazały, że dynamika pojazdu miała znaczący wpływ, podczas gdy warunki zewnętrzne miały minimalny wpływ na pomiary.
- **Logika rozmyta dla oceny niezawodności.** Niezawodność jest oceniana za pomocą logiki rozmytej, która korzysta z funkcji rozmytych do oceny, w jaki sposób poszczególne parametry wpływają na niepewność pomiarów. Parametry i funkcje przynależności muszą być dostosowane do konkretnej lokalizacji.
- **Znaczenie testów terenowych.** Testy terenowe mogą pomóc w ustaleniu wartości krytycznych, których przekroczenie prowadzi do zwiększenia niepewności pomiarów. Przykładowo, w jednym badaniu opisanym w niniejszym dokumencie normatywny zakres prędkości wynosił 40-65 km/h.

3. Eksperymenty i wdrożenia

- **Procent przejazdów z potencjalną niepewnością.** Ponad 40% zarejestrowanych przejazdów pojazdów zawierało czynniki, które mogły zwiększyć niepewność pomiarów, a około 20% analizowanych pomiarów uznano za potencjalnie niewiarygodne.
- **Wpływ parametrów na wskaźnik niezawodności.** Pojedynczy parametr lub ich kombinacja może zmniejszyć ogólny wskaźnik niezawodności poniżej 50%. Przesunięcie było najczęstszym izolowanym parametrem prowadzącym do potencjalnie niewiarygodnych pomiarów, podczas gdy prędkość i przyspieszenie były najczęściej związane z wieloma nienormalnymi parametrami.
- **Algorytm oceny wiarygodności.** Opracowany algorytm do oceny wiarygodności pomiarów masy jest odpowiedni do stosowania w HS-WIM do bezpośredniego egzekwowania przepisów, jednak wymaga wcześniejszej analizy parametrów normalnych w każdym indywidualnym miejscu, gdzie system działa.

3.3.4. Estymacja wagi pojazdu

W ramach prowadzonych badań przeanalizowano trzy znane metody estymacji wagi pojazdu na podstawie sygnału z czujników wagowych oraz zaproponowano nową metodę, opartą na regresji z wykorzystaniem Lasu losowego opisanego w rozdziale 2.16.



Rysunek 3.33. Przykładowy przejazd przez czujniki wagowe W1 i W2 na stanowisku badawczym. Źródło: materiały firmy APM PRO

W badaniach przetestowano cztery metody wyznaczania masy pojazdu na podstawie sygnałów z czujników wagowych. Przykładowe sygnały z czujników wagowych przedstawiono

3.3. Badania dotyczące sygnałów z czujników wagowych

na rys. 3.33. Metoda 4 została zaproponowana, w stosunku do standardowo używanych metod opisanych w literaturze (metody 1-3) 2.17.

- **Metoda 1** – na podstawie maksymalnej wartości sygnału.
- **Metoda 2** – obliczanie pola pod krzywą sygnału.
- **Metoda 3** – resampling sygnału, a następnie obliczenie pola pod krzywą sygnału.
- **Metoda 4** – stworzenie modelu regresji z wykorzystaniem Lasu losowego, który estymuje wagę pojazdu na podstawie maksymalnej wartości sygnału.


Do testów metod estymacji wagi pojazdu wykorzystano samochód dostawczy Iveco 50c13 z 2001 roku, o masie całkowitej około 2000 kg wymiary przedstawiono na rys. 3.35. Wykonano 9 przejazdów testowych, na podstawie których uzyskano sygnały z dwóch czujników wagowych zainstalowanych w nawierzchni drogi. Pogląd na stację pomiarową i przejeżdżający pojazd przedstawiono na rys. 3.34. Sygnał z jednego czujnika reprezentował odczyty dla lewej strony pojazdu, a sygnał z drugiego czujnika reprezentował odczyty dla prawej strony pojazdu – najpierw przedniego koła, a następnie tylnego. Masę całkowitą uzyskano, sumując estymacje wag dla sygnałów z poszczególnych kół.

Uzyskane wyniki dla poszczególnych metod pokazują, że Metoda 2 oraz Metoda 4 dały wyniki najbardziej zbliżone do rzeczywistej całkowitej masy pojazdu co pokazano na rys. 3.36.

3. Eksperymenty i wdrożenia

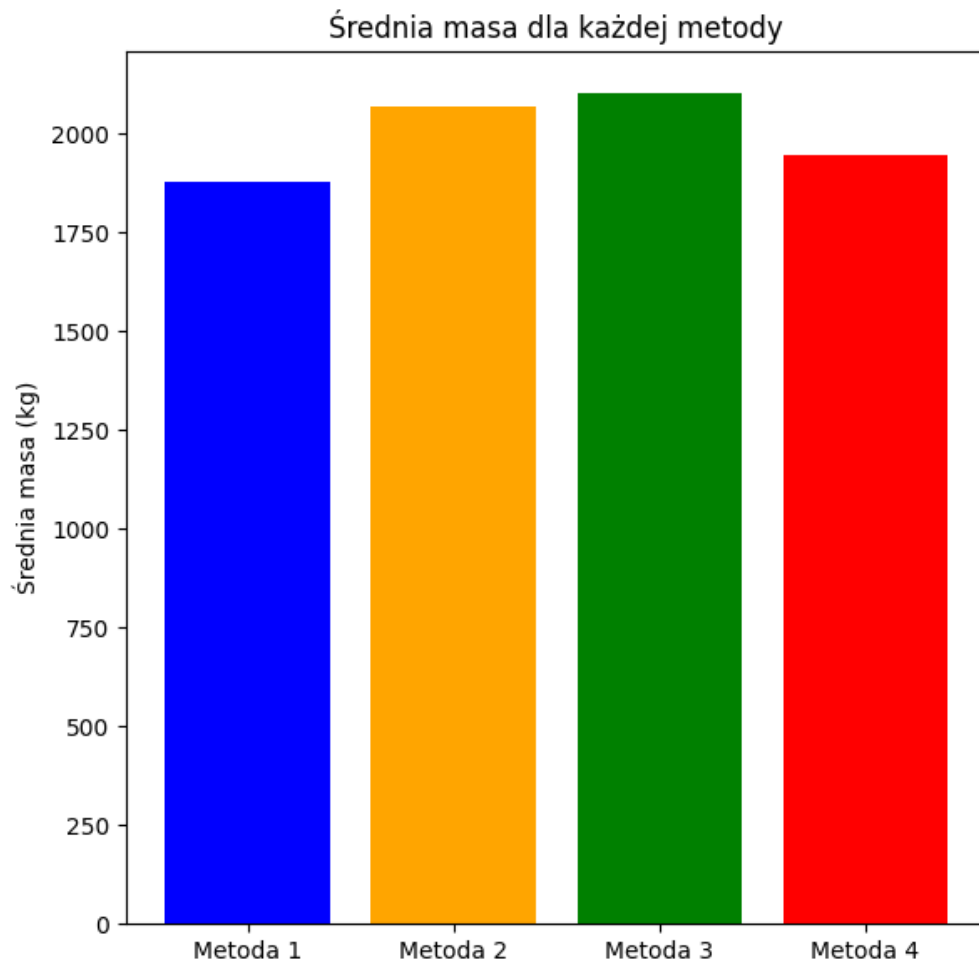


Rysunek 3.34. Widok samochodu dostawczego przejeżdżającego przez stację testową.
Źródło: materiały firmy APM PRO



Rysunek 3.35. Wymiary samochodu dostawczego Iveco 50c13. Źródło: materiały reklamowe firmy Iveco


3.3. Badania dotyczące sygnałów z czujników wagowych




Rysunek 3.36. Porównanie metod wyznaczania mas różnymi metodami – średnia masa pojazdu. Źródło: opracowanie własne

Ponadto, Metoda 1 oraz Metoda 4 wykazały najmniejsze odchylenie standardowe w estymacji wagi pojazdu, sumując wagi estymowane z wszystkich przejazdów co pokazano na rys. 3.37 oraz rys.3.38.

3. Eksperymenty i wdrożenia



Rysunek 3.37. Porównanie metod wyznaczania mas różnymi metodami. Źródło: opracowanie własne



Rysunek 3.38. Porównanie metod wyznaczania mas różnymi metodami – odchylenie standardowe. Źródło: opracowanie własne

3.4. Eksploracja profilu magnetycznego pojazdu

Podsumowując, spośród testowanych metod proponowanych w literaturze, najlepsze wyniki dawała Metoda 2. Uzyskiwano wyniki najbardziej zbliżone do rzeczywistych, jednak Metoda 1 wykazała najbardziej stabilne odczyty. W związku z tym, stosując odpowiednie współczynniki korekcji, możliwe jest uzyskanie najlepszych rezultatów.

Zaproponowana Metoda 4, oparta na uczeniu maszynowym, wykazuje potencjał bycia najlepszą metodą estymacji wagi pojazdu pod względem dokładności estymacji oraz stabilności odczytów. Jednak aby potwierdzić tę tezę, konieczne będą dalsze badania na większej liczbie pojazdów różnych klas oraz z pojazdami wstępnie zważonymi na legalizowanych wagach.

3.4. Eksploracja profilu magnetycznego pojazdu

3.4.1. Klasyfikacja modelu i marki pojazdu

Zbadano możliwości wykrycia modelu i marki pojazdu na podstawie sygnału z pojedynczej szerokiej pętli indukcyjnej, wykonanej według standardu TLS. Do badania wykorzystano obrazy stworzone z sygnału oraz z poszczególnych transformat. Wykresy były skalowane tak, aby zawsze miały tę samą liczbę próbek, co zapewniało odpowiednie proporcje obrazów niezależnie od prędkości przejazdu i innych czynników mogących wpływać na pomiar.

Obrazy, które ostatecznie posłużyły jako baza do uczenia i testowania klasyfikatora, uzyskano, łącząc trzy elementy: profil sygnału w domenie czasu (profil magnetyczny sygnału), wynik zastosowania transformaty Fouriera (FFT), który przedstawia sygnał w domenie częstotliwości, oraz część zespoloną odwrotnej transformaty Fouriera, która ukazuje informacje o fazie sygnału.

Do klasyfikacji obrazów wybrano sieć YOLOX [43], która jest algorytmem detekcji obiektów opartym na sieciach neuronowych. YOLO (*You Only Look Once*) wykorzystuje technikę detekcji jednego przebiegu, co polega na przetwarzaniu obrazu przez sieć neuronową tylko raz, podczas gdy inne techniki detekcji obiektów wykorzystują wielokrotne przetwarzanie. Główną zaletą YOLOX jest możliwość wykrywania obiektów w czasie rzeczywistym, dzięki czemu może być stosowany w aplikacjach, takich jak samochody autonomiczne.


Wybrano osiem modeli pojazdów do nauczania sieci neuronowej:

- Toyota Corolla,
- Ford Mondeo,
- Volvo XC60,


3. Eksperymenty i wdrożenia

- Kia Sportage,
- Audi A3,
- Hyundai I30,
- Toyota Yaris,
- Skoda Octavia.

Specjalnie wybrano część samochodów produkowanych na tej samej płycie podłogowej, aby sprawdzić, czy sieć neuronowa poradzi sobie z kategoryzowaniem pojazdów o bardzo podobnych profilach magnetycznych. Przykładem są Ford Mondeo i Volvo XC60, które były do 2014 roku produkowane na wspólnej platformie EUCD. Ich profile magnetyczne przedstawiono kolejno na rys. 3.39 oraz rys. 3.40.



Rysunek 3.39. Profil magnetyczny Forda Mondeo starszej generacji: u góry profil magnetyczny, lewy dolny róg - FFT, prawy dolny róg - część zespolona odwróconej FFT Źródło: opracowanie własne




Rysunek 3.40. Profil magnetyczny Volvo XC60: u góry profil magnetyczny, lewy dolny róg - FFT, prawy dolny róg - część zespolona odwróconej FFT Źródło: opracowanie własne

3.4. Eksploracja profilu magnetycznego pojazdu

Ford Mondeo i Volvo XC60 były do 2014 roku produkowane na wspólnej płycie podłogowej [2]. Dotyczy to pierwszej generacja Volvo XC60 (2008-2017) oraz produkowanego w latach 2007-2014 Forda Mondeo. Oba modele miały tę samą platformę o nazwie EUCD [3].

Skoda Octavia i Audi A3 również posiadają wspólną płytę podłogową – (platforma MQB) [1].

W zbiorze testowym i uczącym znalazły się obrazy profilu magnetycznego pojazdów z różnych roczników w kilku wersjach nadwozia. Przykład dla dwóch różnych wersji Forda Mondeo przedstawiono na rys. 3.41.



Rysunek 3.41. Profile magnetyczne różnych wersji Forda Mondeo. Źródło: opracowanie własne

W zbiorze uczącym i testowym znalazły się zarówno samochody typu sedan, kombi, czy hatchback (oraz inne typy występujące w ramach danego modelu i marki).

Na podstawie danych z stacji iWIM zlokalizowanej na drodze krajowej 44 w Mikołowie, na której jest zainstalowana kamera obsługująca wykrywanie modelu i marki przejeżdżającego pojazdu, pobrano 80000 rekordów. Dla każdego modelu i marki z wybranych i wymienionych wcześniej pobrano po 10000 rekordów.

Po weryfikacji danych okazało się, że duża część z danych była nieprawidłowo sklasyfikowana przez kamerę, w związku z czym takie rekordy trzeba było odrzucić. Ostatecznie

3. Eksperymenty i wdrożenia

wyodrębniono dwa niezależne zbiory: uczący i testowy. Liczebności zbiorów przedstawiono w tabeli 3.10.

Tabela 3.10. Liczebności zbiorów uczących i testowych dla poszczególnych typów pojazdów

	Toyota Corolla	Audi A3	Ford Mondeo	Kia Sportage	Volvo XC60	Hyundai I30	Skoda Octavia	Toyota Yaris
Liczba rekordów w zbiorze uczącym	100	100	100	100	100	100	100	100
Liczba rekordów w zbiorze testowym	37	38	33	34	36	36	39	35


Do uczenia i testowania na podstawie sygnałów z pętli indukcyjnej (profilu magnetycznych) utworzono obrazy składające się z:

1. Profilu magnetycznego pojazdu (na osiach: y – częstotliwość, x – czas).
2. Wyniku szybkiej transformaty Fouriera (FFT) sygnału profilu magnetycznego przedstawionego na wykresie w skali logarytmicznej w dziedzinie częstotliwości (y – amplituda, x – częstotliwość).
3. Rekonstrukcji sygnału z FFT przez zastosowanie odwrotnej transformaty Fouriera - IFFT (z dziedziny częstotliwości do dziedziny czasu) z profilu magnetycznego (y – częstotliwość, x – czas). Wykres przedstawiony w skali logarytmicznej. Na wykresie pozostawiono tylko część urojoną.

Przykładowe obrazy powstałe na podstawie profilu magnetycznego dla poszczególnych pojazdów:


Profil magnetyczny Forda Mondeo rys. 3.42

3.4. Eksploracja profilu magnetycznego pojazdu



Rysunek 3.42. Profil magnetyczny – Ford Mondeo: u góry profil magnetyczny, lewy dolny róg - FFT, prawy dolny róg - część zespolona odwróconej FFT. Źródło: opracowanie własne


Profil magnetyczny Volvo XC60 rys. 3.43



Rysunek 3.43. Profil magnetyczny – Volvo XC60: u góry profil magnetyczny, lewy dolny róg - FFT, prawy dolny róg - część zespolona odwróconej FFT. Źródło: opracowanie własne


Profil magnetyczny Kia Sportage rys. 3.44.

3. Eksperymenty i wdrożenia



Rysunek 3.44. Profil magnetyczny – Kia Sportage: u góry profil magnetyczny, lewy dolny róg - FFT, prawy dolny róg - część zespolona odwróconej FFT. Źródło: opracowanie własne


Profil magnetyczny Audi A3 rys. 3.45.



Rysunek 3.45. Profil magnetyczny – Audi A3: u góry profil magnetyczny, lewy dolny róg - FFT, prawy dolny róg - część zespolona odwróconej FFT. Źródło: opracowanie własne


Profil magnetyczny Hyundai I30 rys. 3.46.

3.4. Eksploracja profilu magnetycznego pojazdu



Rysunek 3.46. Profil magnetyczny – Hyundai I30: u góry profil magnetyczny, lewy dolny róg - FFT, prawy dolny róg - część zespolona odwróconej FFT. Źródło: opracowanie własne


Profil magnetyczny Toyoty Corolli rys. 3.47.



Rysunek 3.47. Profil magnetyczny – Toyota Corolla: u góry profil magnetyczny, lewy dolny róg - FFT, prawy dolny róg - część zespolona odwróconej FFT. Źródło: opracowanie własne


Profil magnetyczny Toyoty Yaris rys. 3.48.

3. Eksperymenty i wdrożenia



Rysunek 3.48. Profil magnetyczny – Toyota Yaris: u góry profil magnetyczny, lewy dolny róg - FFT, prawy dolny róg - część zespolona odwróconej FFT. Źródło: opracowanie własne


Profil magnetyczny Skody Octavi rys. 3.49.



Rysunek 3.49. Profil magnetyczny – Skoda Octavia: u góry profil magnetyczny, lewy dolny róg - FFT, prawy dolny róg - część zespolona odwróconej FFT. Źródło: opracowanie własne

Do stworzenia modelu na podstawie obrazów wykorzystano YOLOX. Wyniki działania modelu – średnia średniej precyzji (mAP) jest obliczana na podstawie średniego AP dla wszystkich klas wyniki dla poszczególnych typów pojazdów zamieszczono na rys. 3.50.

3.4. Eksploracja profilu magnetycznego pojazdu



Rysunek 3.50. mAP - średnia precyzja dla wszystkich klas. Źródło: opracowanie własne

Wyniki działania modelu na podstawie testów na zbiorze testowym:

- Suma rekordów w zbiorze testowym: 288.
- Suma błędnie odczytanych rekordów: 6.
- Suma podwójnie sklasyfikowanych rekordów, gdzie ufność klasyfikacji była większa dla nieprawidłowej klasy: 3.
- Poprawność klasyfikacji marki i modelu, biorąc pod uwagę, że tam gdzie występowało wykrycie kilku klas, jest wzięty pod uwagę rekord z najwyższą ufnością: 96,88% szczególne wyniki zestawiono w 3.11.

3. Eksperymenty i wdrożenia

Tabela 3.11. Wyniki klasyfikacji dla poszczególnych pojazdów

	Toyota Corolla	Audi A3	Ford Mondeo	Kia Sportage	Volvo XC60	Hyundai I30	Skoda Octavia	Toyota Yaris	Σ
Liczba rekordów w zbiorze testowym	37	38	33	34	36	36	39	35	288
Liczba rekordów błędnie sklasyfikowanych	1	0	1	0	0	3	1	0	6
Liczba rekordów sklasyfikowanych podwójnie, gdzie ufność nieprawidłowej klasy była większa	2	0	0	0	0	1	0	0	3
Dokładność klasyfikacji	92%	100%	97%	100%	100%	89%	97%	100%	97%

Błędnie sklasyfikowane rekordy:

- 2x Hyundai I30 sklasyfikowana jako Audi A3,
- 1x Hyundai I30 sklasyfikowana jako Toyota Corolla,
- 1x Skoda Octavia sklasyfikowana jako Audi A3,
- 1x Ford Mondeo sklasyfikowana jako Hyundai I30 ,
- 1x Toyota Corolla sklasyfikowana jako Skoda Octavia.

Błędnie sklasyfikowane rekordy, gdzie ufność nieprawidłowej klasy była większa (co oznacza, że klasyfikator wykrył prawidłową klasę jednak oznaczył, że bardziej prawdopodobne było wystąpienie błędnej klasy):

- 1x Toyota Corolla sklasyfikowana jako Ford Mondeo,
- 1x Toyota Corolla sklasyfikowana jako Hyundai I30,
- 1x Hyundai I30 sklasyfikowana jako Audi A3.

Na podstawie testów można jednoznacznie stwierdzić, że możliwe jest rozpoznawanie modelu i marki samochodu w oparciu o profile magnetyczne. Badania zostały wykonane tylko w ramach klasy 7 – samochody osobowe według klasyfikacji TLS 8+1.

3.4. Eksploracja profilu magnetycznego pojazdu

Dalszych badań wymaga sprawdzenie, czy dokładność klasyfikacji nie spadnie przez poszerzenie liczby modeli i marek, które mogą być błędnie rozpoznawane przez podobieństwo do siebie profili magnetycznych, tak jak to miało miejsce w przypadku Hyundai I30 oraz Audi A3. Następnie, trzeba sprawdzić, czy w ramach innych klas pojazdów (8 – samochody ciężarowe z przyczepą, 9 – samochody ciężarowe z ciągnikiem siodłowym, 7 – samochody osobowe, 5 – autobusy, 3 – samochody ciężarowe, 2 – samochody osobowe z przyczepą, 10 – motocykle) jesteśmy w stanie klasyfikować model i markę.

Stworzenie klasyfikacji modelu i marki w połączeniu z koncepcją estymacji wagi pojazdu [70] na podstawie profilu magnetycznego mogłoby pozwolić na stworzenie bazy profili magnetycznych odniesienia dla każdego modelu i marki pojazdu i ostatecznie pozwolić na rzeczywistą estymację wagi pojazdów przy pomocy pętli indukcyjnych.

4. Podsumowanie

Celem przeprowadzonych badań było zbadanie możliwości zwiększenia funkcjonalności stacji ważenia pojazdów w ruchu (WIM) poprzez zastosowanie zaawansowanych algorytmów przetwarzania sygnałów z czujników. Badania koncentrowały się na obronie trzech kluczowych tez:

- Odpowiednio dobrane i zaprojektowane algorytmy przetwarzania sygnałów z czujników mogą znacząco zwiększyć funkcjonalność stacji WIM, bez konieczności istotnej rozbudowy infrastruktury fizycznej.
- Zastosowanie odpowiednich algorytmów oraz oprogramowania do przetwarzania danych umożliwia uruchomienie stacji ważenia pojazdów w ruchu do celów administracyjnych.
- Istnieją algorytmy przetwarzania sygnałów, które zastosowane w przypadku niestacjonarnych systemów ważenia pojazdów w ruchu (WIM) wykazują wysoką odporność na zmieniające się warunki operacyjne i środowiskowe.

4.1. Zwiększenie funkcjonalności stacji WIM poprzez algorytmy przetwarzania sygnałów

W trakcie badań potwierdzono, że odpowiednio dobrane algorytmy przetwarzania sygnałów mogą znacząco podnieść funkcjonalność stacji WIM. Przykłady takich zastosowań obejmują wykorzystanie technik, takich jak analiza czynnikowa, różne algorytmy uczenia maszynowego oraz regresory oparte na algorytmie losowego lasu, do bardziej precyzyjnego ważenia pojazdów oraz uzyskiwania dodatkowych informacji, takich jak estymacja prędkości, długości pojazdu, a także klasyfikatory służące do identyfikacji modelu i marki pojazdu, liczby

4. Podsumowanie

osi i wielu innych aspektów omówionych w niniejszej pracy. Wyniki te sugerują, że implementacja odpowiednich algorytmów umożliwi rozszerzenie funkcji istniejących stacji WIM bez konieczności rozbudowy infrastruktury fizycznej, co potwierdza pierwszą tezę.

4.2. Wykorzystanie stacji WIM do celów administracyjnych za pomocą odpowiednich algorytmów

Badania wykazały również, że zastosowanie zaawansowanych algorytmów i oprogramowania do przetwarzania danych może umożliwić wykorzystanie stacji WIM do celów administracyjnych. Opracowanie systemu iWIM, który integruje różne technologie czujników z zaawansowanymi metodami analizy danych, pozwoliło na wdrożenie algorytmu oceny wiarygodności pomiarów. Algorytm ten, oparty na logice rozmytej, umożliwia w czasie rzeczywistym ocenę poprawności każdego pomiaru, co jest kluczowe dla wdrożenia systemów WIM do bezpośredniego egzekwowania przepisów drogowych. Uzyskane wyniki potwierdzają, że druga teza pracy jest zasadna.

4.3. Transferowalność i adaptacyjność algorytmów WIM

Opracowane w ramach pracy algorytmy przetwarzania sygnałów wykazały się wysoką transferowalnością i zdolnością do adaptacji do zmieniających się warunków operacyjnych i środowiskowych. Przykładem są algorytmy klasyfikacji oparte na sygnałach z pętli indukcyjnych, które były testowane na różnych stacjach pomiarowych lub z zestawami takich samych czujników. Również algorytmy klasyfikacji pojazdów na podstawie danych z czujników ważenia pojazdów w ruchu zostały przetestowane i wdrożone na kilkudziesięciu pasach ruchu. Wprowadzenie takich algorytmów zwiększa praktyczną użyteczność systemów WIM w różnorodnych scenariuszach drogowych, co potwierdza trzecią tezę pracy.

4.4. Podsumowanie oryginalnego wkładu autora

Przeprowadzone badania przyczyniają się do rozwoju narzędzi, które mogą zwiększyć zdolność monitorowania ruchu drogowego, poprawić płynność ruchu, a tym samym zmniejszyć emisję zanieczyszczeń oraz podnieść poziom bezpieczeństwa na drogach.

Niniejsza praca stanowi w pełni indywidualne dzieło autora, jednakże niektóre tezy i badania zostały opracowane oraz przeprowadzone w ramach zespołów badawczych, w których

4.4. Podsumowanie oryginalnego wkładu autora

autor uczestniczył. W związku z tym, te elementy nie są wyłącznym wkładem autora. Niemniej, starano się precyzyjnie wskazać oryginalny wkład autora w każdym rozdziale, co zostało szczegółowo przedstawione poniżej. Wyszczególniono również opublikowane artykuły (z wyłączeniem tych będących w trakcie procesu wydawniczego) oraz dwa najważniejsze wystąpienia konferencyjne spośród ośmiu, podczas których zaprezentowano wyniki niniejszej pracy.

Oryginalny wkład autora obejmujący zaproponowanie metod, projektowanie, badania, tworzenie, testy, opis oraz wdrożenie:

1. Regresorów do estymacji długości pojazdu: podejście 1 (rozdział 3.2.2) oraz podejście 2 (rozdział 3.2.7). Co zostało przedstawione w artykule [57].
2. Klasyfikatora do określania liczby osi pojazdu (rozdział 3.2.3). Co zostało przedstawione w artykule [57].
3. Klasyfikatorów pojazdów na podstawie sygnałów z pętli indukcyjnych: podejście 1 (rozdział 3.2.4) oraz podejście 2 (rozdział 3.2.5). Co zostało przedstawione w [57] oraz [56].
4. Metody estymacji wagi pojazdu na podstawie sygnałów z czujników wagowych (rozdział 3.3.4).
5. Klasyfikatora modelu i marki pojazdu na podstawie profilu magnetycznego (rozdział 3.4.1).

Oryginalny wkład autora jako jednego z głównych autorów w zespole badawczym, obejmujący zaproponowanie metod, projektowanie, badania, tworzenie, testy oraz opis:

1. Klasyfikatora pojazdów na podstawie sygnałów z pętli indukcyjnych - podejście 3 (rozdział 3.2.6).

Oryginalny wkład autora jako autora pomocniczego w zespole badawczym, obejmujący implementację, badania, testy, opis, wdrożenie oraz analizę statystyczną po wdrożeniu:

1. Klasyfikacja na podstawie sygnałów z czujników wagowych: podejście 1 (rozdział 3.3.1) oraz podejście 2 (rozdział 3.3.2). Co zostało przedstawione w [86] oraz [55].
2. Badania nad nowymi algorytmami do oceny wiarygodności pomiarów na podstawie ważenia pojazdów w ruchu (rozdział 3.3.3). Co zostało przedstawione w artykułach konferencyjnych i ogłoszone na konferencjach naukowych przez autora niniejszej pracy [53] na XIV międzynarodowej konferencji Transport Problems 2022 która odbyła się w Katowicach oraz [58] na międzynarodowej konferencji Technology Convergence 2023 Setting the Wheels in Motion: Reimagining the Future of Heavy Vehicles, Roads and Freight która odbyła się w Brisbane w Australii oraz zostało przedstawione w artykułach [12] oraz [54].


5. Zestawy danych

5.1. Dane z pętli indukcyjnych szerokich z drogi krajowej 44

Pętle indukcyjne na drodze krajowej 44 są wbudowane w nawierzchnię asfaltową. Są to pętle szerokie wybudowane według standardów TLS. Wymiary są przedstawione w tab. 5.1 oraz 5.1. Układ akwizycji danych z pętli zapisuje tylko część urojony sygnału.

Tabela 5.1. Wymiary pętli indukcyjnych na drodze DK44

Wymiar	A	B
Wartość (cm)	100	200




Rysunek 5.1. Pętla zamontowana na stanowisku na drodze DK44. Źródło: opracowanie własne

Częstotliwość wzbudzenia pętli wynosi około 100 kHz.


5. Zestawy danych

5.1.1. Profile magnetyczne uzyskiwane na stacji

Przykładowe profile magnetyczne dla poszczególnych klas przedstawiono na rysunkach 5.2, 5.3, 5.4, 5.5, 5.6, 5.7, 5.8.




Rysunek 5.2. Profil magnetyczny samochodu osobowego z przyczepą. Klasa 2 według TLS 8+1. Źródło: opracowanie własne




Rysunek 5.3. Profil magnetyczny ciężarówki. Klasa 3 według TLS 8+1. Źródło: opracowanie własne

5.1. Dane z pętli indukcyjnych szerokich z drogi krajowej 44




Rysunek 5.4. Profil magnetyczny autobusu. Klasa 5 według TLS 8+1. Źródło: opracowanie własne




Rysunek 5.5. Profil magnetyczny samochodu osobowego. Klasa 7 według TLS 8+1. Źródło: opracowanie własne

5. Zestawy danych




Rysunek 5.6. Profil magnetyczny ciężarówki z przyczepą. Klasa 8 według TLS 8+1.
Źródło: opracowanie własne



Rysunek 5.7. Profil magnetyczny ciągnika siodłowego z naczepą. Klasa 9 według TLS 8+1. Źródło: opracowanie własne

5.2. Dane z pętli indukcyjnych szerokich i wąskich z układu akwizycji danych AGH



Rysunek 5.8. Profil magnetyczny samochodu dostawczego. Klasa 11 według TLS 8+1. Źródło: opracowanie własne


5.2. Dane z pętli indukcyjnych szerokich i wąskich z układu akwizycji danych AGH

Stacja przez którą poruszają się pojazdy na kampusie AGH jest skonstruowana z 4 czujników zamontowanych w nawierzchni asfaltowej na drodze wewnętrznej, kamery pogładowej oraz układu akwizycji rys. 5.9. Układ akwizycji zaprojektowany przez zespół naukowców z AGH jest w stanie wykonywać akwizycję części urojonej oraz rzeczywistej sygnału z pętli.

5. Zestawy danych

Table 1. Loops dimensions.

Dimension	A	B	C	D	E	F
Value (cm)	100	200	10	320	20	150



Rysunek 5.9. AGH stacja z pętłami indukcyjnymi, przez którą poruszają się pojazdy.
Źródło: materiały AGH

Częstotliwości wzbudzeń na jakich pracują pętle przedstawiono w tabeli 5.2.

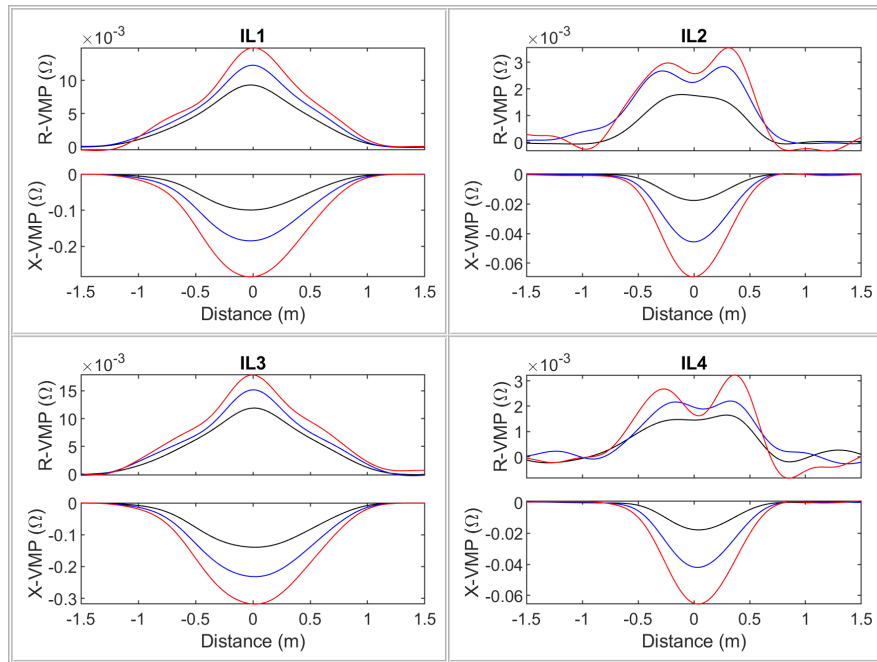
Tabela 5.2. Częstotliwości wzbudzeń pętli indukcyjnych na stacji AGH

Wartość częstotliwości w kHz na danym kanale:	f1	f2	f3
#1: dla pierwszego standardowego czujnika IL1	10	18	27
#3: dla drugiego standardowego czujnika IL3	13	21	28
#2: dla pierwszego wąskiego czujnika IL2	6	15	22
#4: dla drugiego wąskiego czujnika IL4	7	16	24

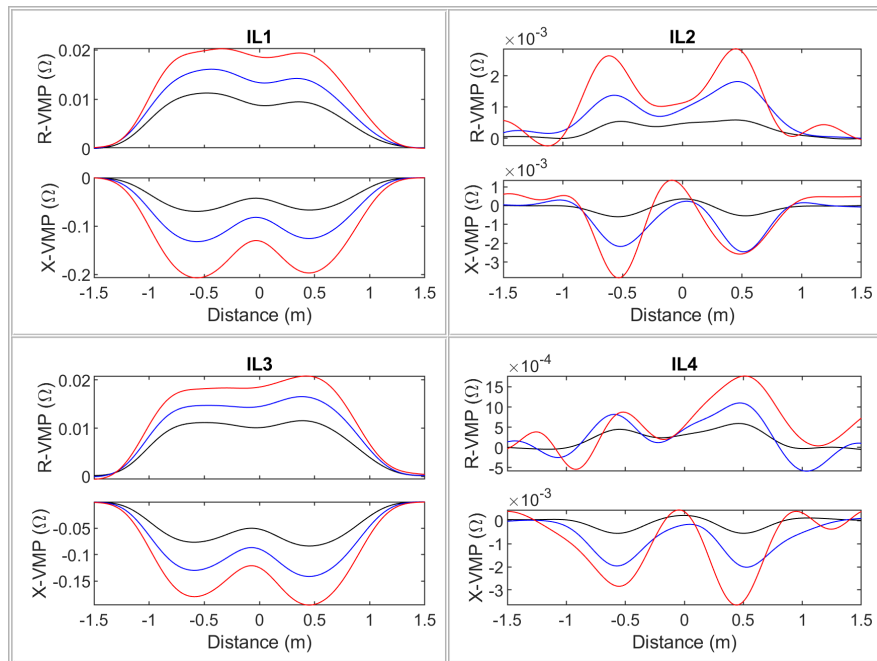
5.2.1. Profile magnetyczne uzyskiwane na stacji AGH

Przykładowe profile magnetyczne różnych klas pojazdów przedstawiono na rys. 5.10, 5.11, 5.12, 5.13, 5.14, 5.15.

5.2. Dane z pętli indukcyjnych szerokich i wąskich z układu akwizycji danych AGH

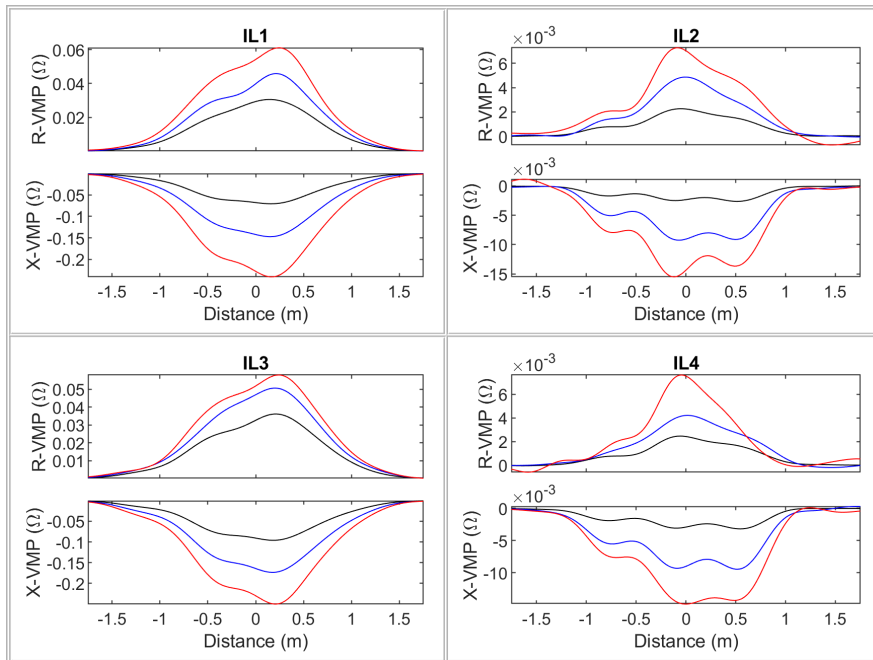


Rysunek 5.10. Profil magnetyczny skutera. Źródło: materiały AGH

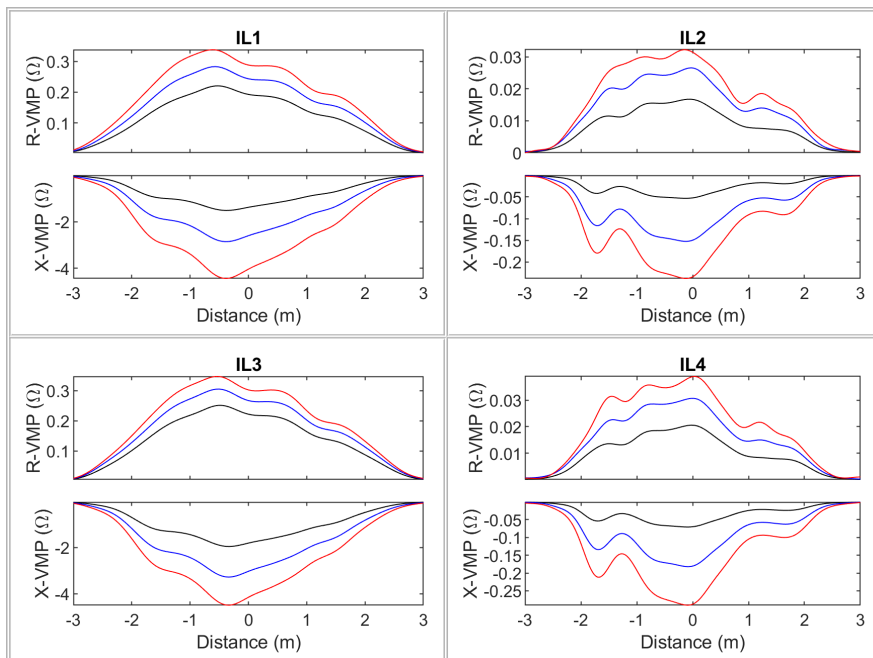


Rysunek 5.11. Profil magnetyczny roweru. Źródło: materiały AGH

5. Zestawy danych

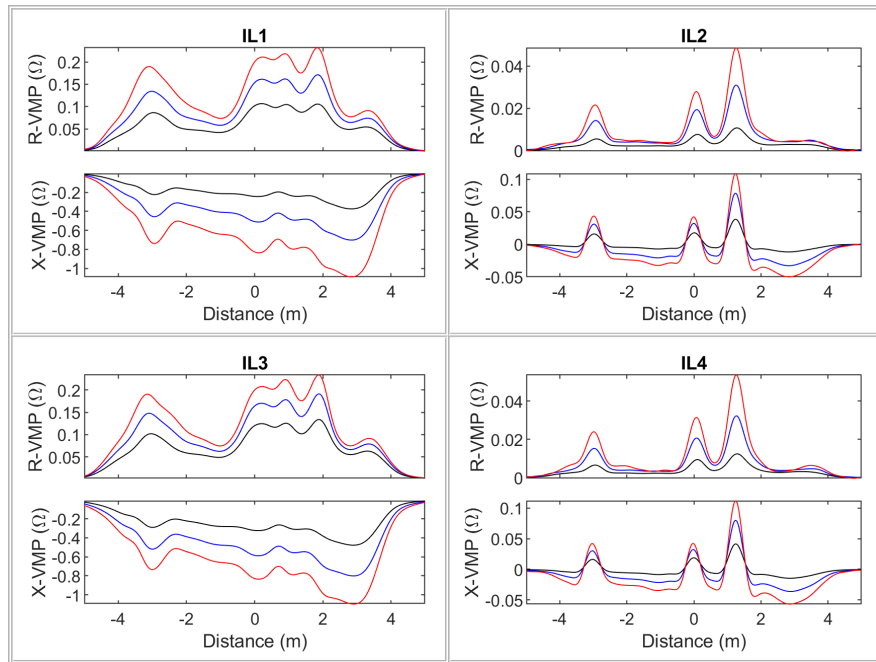


Rysunek 5.12. Profil magnetyczny motocykla. Klasa 10 według TLS 8+1. Źródło: materiały AGH

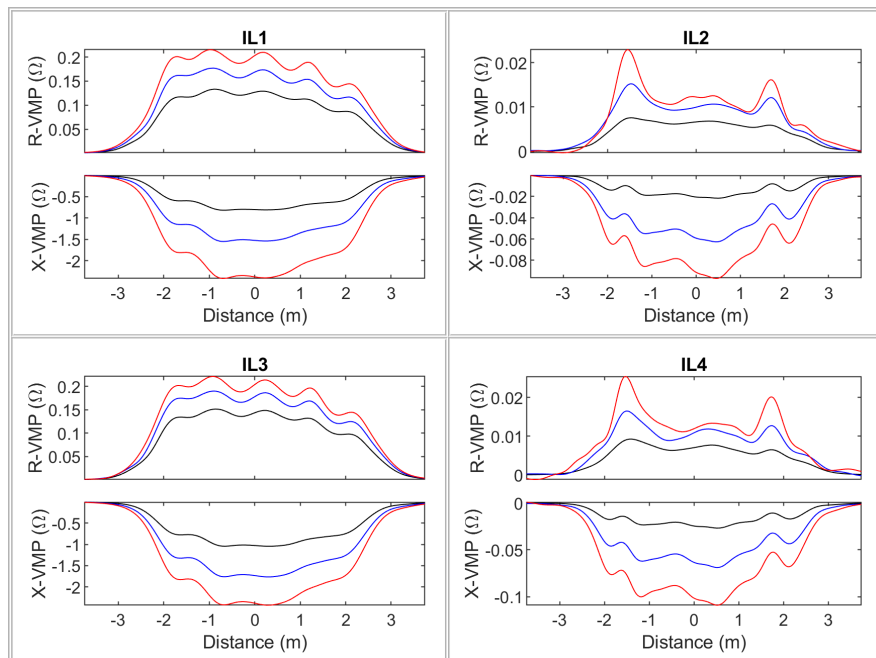


Rysunek 5.13. Profil magnetyczny samochodu osobowego. Klasa 7 według TLS 8+1. Źródło: materiały AGH

5.2. Dane z pętli indukcyjnych szerokich i wąskich z układu akwizycji danych AGH




Rysunek 5.14. Profil magnetyczny ciężarówki. Klasa 3 według TLS 8+1. Źródło: materiały AGH



Rysunek 5.15. Profil magnetyczny samochodu dostawczego. Klasa 11 według TLS 8+1. Źródło: materiały AGH

5.3. Dane RAW z czujników ważenia pojazdów w ruchu


W zależności od stopnia dokładności, który chcemy uzyskać na stacji ważenia pojazdów w ruchu, stosuje się różne ilości czujników wagowych, które są zabudowane w nawierzchni drogi.




Rysunek 5.16. Przykładowe rozmieszczenie 4 czujników pomiarowych (L – pętla indukcyjna, w – waga tensometryczna). Źródło: materiały firmy APM PRO

Dane uzyskiwane podczas przejazdu to, w przypadku przedstawionym na rys. 5.16, dwa sygnały, które składają się na przejazd i naciski lewej strony pojazdu rys. 5.17 oraz przejazd i naciski prawej strony pojazdu rys. 5.18 .

5.3. Dane RAW z czujników ważenia pojazdów w ruchu



Rysunek 5.17. Przykładowy sygnał z wagi W1. Źródło: opracowanie własne



Rysunek 5.18. Przykładowy sygnał z wagi W2. Źródło: opracowanie własne

6. Narzędzia programowe i kody

W programowaniu głównie wykorzystywano język programowania Python. w szczególności biblioteki:

- `time`
- `binascii`
- `csv`
- `serial`
- `numpy`
- `struct`
- `datetime`
- `os`
- `statistics`
- `matplotlib.pyplot`
- `sklearn.ensemble.RandomForestRegressor`
- `base64`
- `ujson` (jako `json`)
- `scipy.fft` (w tym funkcje: `rfft`, `rfftfreq`, `fft`, `fftfreq`, `fftshift`)
- `scipy.fftpack.fft`
- `scipy.io.wavfile`
- `kymatio.numpy.Scattering1D`
- `kymatio.datasets.fetch_fsdd`
- `pywt`
- `pylab`
- `scipy.signal` (w tym funkcje: `decimate`, `savgol_filter`, `chirp`, `spectrogram`, `argrelextrema`)

6. Narzędzia programowe i kody

- `scipy.optimize` (w tym funkcje: `linprog`, `minimize`, `quadratic_assignment`)
- `glob`
- `czst`
- `scipy.stats` (w tym funkcje: `moment`, `norm`, `kurtosis`, `skew`)
- `detecta.detect_peaks`
- `sys`
- `sklearn.preprocessing.Normalizer`
- `sklearn.decomposition` (w tym `FactorAnalysis`, `PCA`)
- `sklearn.preprocessing` (w tym `StandardScaler`, `MinMaxScaler`)
- `joblib`
- `torch`
- `copy.deepcopy`
- `re`
- `scipy.linalg`
- `pandas`
- `scipy.special.softmax`
- `sklearn.model_selection.train_test_split`
- `sklearn.neural_network.MLPClassifier`
- `sklearn.metrics` (w tym funkcje: `accuracy_score`, `confusion_matrix`, `classification_report`, `cohen_kappa_score`, `mean_absolute_error`, `mean_squared_error`, `roc_auc_score`, `precision_recall_curve`, `auc`, `matthews_corrcoef`)
- `sklearn.ensemble` (w tym `RandomForestClassifier`, `VotingClassifier`)
- `sklearn.datasets.fetch_california_housing`
- `sklearn.linear_model.LogisticRegression`
- `sklearn.tree.DecisionTreeClassifier`
- `sklearn.svm.SVC`
- `sklearn.neighbors.KNeighborsClassifier`
- `sklearn.naive_bayes.GaussianNB`
- `PIL.Image`
- `shap`
- `ast`
- `scipy.optimize.fsolve`

- `scipy.signal.savgol_filter`
- `scipy.signal.chirp`
- `scipy.signal.spectrogram`
- `scipy.signal.argrelextrema`
- `tensorflow`
- `tensorflow.keras`

Dodatkowo jako klasyfikator obrazów został użyty w jednym z badań YOLOX [43].

Pierwsze próby i badania były projektowane i sprawdzane w programie WEKA (Waikato Environment for Knowledge Analysis) [36].

Bibliografia

- [1] *Płyty podłogowe: Jakie modele powstają na tych samych platformach?*, <https://tinyurl.com/yfhdfbnj>, Accessed: August 31, 2024.
- [2] *Volvo xc60 - autocentrum*, <https://www.autocentrum.pl/volvo/xc60/>, Accessed: August 31, 2024.
- [3] *Zaskakujące pary: Uwierzysz, że te samochody mają tę samą platformę?*, <https://www.auto-swiat.pl/wiadomosci/aktualnosci/zaskakujace-pary-uwierzysz-ze-te-samochody-maja-te-sama-platforme/vjm5wl7>, Accessed: August 31, 2024.
- [4] *European commission cost 334 study - effects of wide single tyres and dual tires*, <https://comt.ca/english/programs/trucking/Pavements/European%20Commission%20COST%20334%20Study%20-%20Effects%20of%20Wide%20Single%20Tyres%20and%20Dual%20Tires%202001.pdf>, 2001, Accessed: 2024-08-28.
- [5] AnalytixLabs, *Random forest regression: How it helps in predictive analytics*, 2023, Accessed: 2024-08-31.
- [6] APM, *Wim pro - apm*, <https://apm.pl/pl/rozwiazania/wim-pro/>, Dostęp: 29 sierpnia 2024 r.
- [7] BAST, *TLS 2012. technische lieferbedingungen für streckenstationen*, Raport techniczny, BAST, 2012, https://www.bast.de/BASt_2017/DE/Publikationen/Regelwerke/Verkehrstechnik/Unterseiten/V5-tls-2012.pdf?__blob=publicationFile&v=1, [dostęp: 05.2021].
- [8] F. M. Belenguer, A. M. Salcedo, A. G. Ibañez, V. M. Sánchez, *Advantages offered by the double magnetic loops versus the conventional single ones*, Plos One (2019), 24.

Bibliografia

- [9] Giuseppe Bonaccorso, *Machine learning algorithms: Popular algorithms for data science and machine learning*, Packt Publishing Ltd, 2018.
- [10] U. Brannolte, W. Griesbach, N. Youssef, R. Opitz, *Wheel load measurement, wim, accuracy, top trial*, Proceedings of the 7th International Symposium of Heavy Vehicle Weights & Dimensions (Delft, The Netherlands), June 16-20 2002, 131–139.
- [11] Peter Bruce, Andrew Bruce, Peter Gedeck, *Practical statistics for data scientists: 50+ essential concepts using r and python*, O'Reilly Media, Inc., 2020.
- [12] Krzysztof Brzozowski, Andrzej Maczyński, Artur Ryguła, Tomasz Konior, *A weigh-in-motion system with automatic data reliability estimation*, *Measurement* **221** (2023), 113494.
- [13] P. Burnos, *Ważenie pojazdów samochodowych w ruchu. część 3: Czujniki nacisku stosowane w systemach weigh in motion (wim)*, *Drogownictwo* **9** (2014), 275–279.
- [14] ———, *Ważenie pojazdów samochodowych w ruchu. część 4: Ocena dokładności systemów weigh in motion*, *Drogownictwo* **12** (2014), 388–395.
- [15] P Burnos, J Gajda, P Piwowar, R Sroka, M Stencel, T Zeglen, *Measurements of Road Traffic Parameters Using Inductive Loops and Piezoelectric Sensors*, *Metrology and Measurement Systems* **14** (2007), Nr 2, 187–203, Publisher: Polish Academy of Sciences, Committee on Metrology and Scientific Instrumentation.
- [16] Piotr Burnos, *Analiza niestacjonarności systemów WIM*, *Pomiary Automatyka Kontrola* (2006), Nr 10, 72 – 76.
- [17] ———, *Autokalibracja systemów ważących pojazdy samochodowe w ruchu oraz analiza i korekcja wpływu temperatury na wynik ważenia*, 2009, Place: Kraków.
- [18] ———, *Ważenie pojazdów samochodowych w ruchu. część 2: Rodzaje i charakterystyka systemów weigh in motion (wim)*, *Drogownictwo* **7-8** (2014), 240–244.
- [19] Piotr Burnos, *Ważenie pojazdów samochodowych w ruchu. część 3: Czujniki nacisku stosowane w systemach weigh in motion (wim)*, *Drogownictwo* **68** (2014), Nr 9, 275–279, Accessed: 2024-08-30.
- [20] Camea Technology, *Weigh in motion (wim) - camea technology*, <https://www.cameatechnology.com/products/wim/>, Accessed: August 29, 2024.

Bibliografia

- [21] Cat Traffic, *Oferta - cat traffic*, <https://cat-traffic.pl/2017/12/01/oferta/>, Dostęp: 29 sierpnia 2024 r.
- [22] D. Cebon, *Handbook of vehicle-road interaction. part 2.vehicle dynamics*, Swets and Zeitlinger BV, Lisse, The Netherlands, 1999.
- [23] L. Chen-Fu, *Investigating inductive loop signature technology for statewide vehicle classification counts*, Raport techniczny, Department of Mechanical Engineering, University of Minnesota, 2018, Final report MN/RC 2018-31.
- [24] Lianyu Chu, Shin-Ting Jeng, Steven Jessberger, *Single-loop vehicle classification and speed measurement using inductive loop signature technology*, Proceedings of NATMEC 2018, CLR Analytics Inc., 2018, Sponsored by USDOT Small Business Innovation Research program.
- [25] B. Coifman, S. Kim, *Speed estimation and length based vehicle classification from freeway single-loop detectors*, *Transportation Research Part C* **17** (2009), 349–364.
- [26] Corinna Cortes, Vladimir Vapnik, *Support-vector networks*, *Machine Learning* **20** (1995), 273–297.
- [27] Cross Traffic, *Crosswim statistics - cross traffic*, <https://www.cross-traffic.com/en/crosswim-statistics/>, Accessed: August 29, 2024.
- [28] _____, *Weigh in motion - cross traffic*, <https://www.cross-traffic.com/en/weigh-in-motion/>, Accessed: August 29, 2024.
- [29] P. K. De Maeijer, G. Luyckx, C. Vuye, E. Voet, W. Van den bergh, S. Vanlanduit, J. Braspeninckx, N. Stevens, J. De Wolf, *Fiber optics sensors in asphalt pavement: State-of-the-art review*, *Infrastructures* **4** (2019), Nr 36.
- [30] Maryam Banitalebi Dehkordi, Abolfazl Zarakia, Rossitza Setchia, *Feature extraction and feature selection in smartphone-based activity recognition*, *Procedia Computer Science* **176** (2020), 2655–2664, Open access under CC BY-NC-ND license.
- [31] E. Doupal, I. Kritz, R. Stamberg, D. Cornu, *One year “wim direct enforcement” experience in czech republic*, Proceedings of the 6th International Conference on Weigh-In-Motion (ICWIM6), 2012.

Bibliografia

- [32] EURAMET, *Guidelines on the calibration of automatic instruments for weighing road vehicles in motion and measuring axle loads. awical wim guide*, SIM, Braunschweig, Germany, 2018.
- [33] Federal Highway Administration, *Traffic monitoring guide: Vehicle types*, 2013, Accessed: 2024-08-31.
- [34] ———, *Long-term bridge performance (ltbp) program protocols*, Raport techniczny, FHWA Office of Infrastructure Research and Development, 2016.
- [35] ———, *Weigh-in-motion pocket guide: Part 1 - wim technology, data acquisition, and procurement guide*, Raport techniczny FHWA-PL-18-015, Office of Highway Policy Information, June 2018.
- [36] Eibe Frank, Mark A. Hall, Ian H. Witten, *The weka workbench*, fourth edition ed., Morgan Kaufmann, 2016, Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques".
- [37] J. Gajda, P. Burnos, R. Sroka, *Administracyjne systemy dynamicznego ważenia pojazdów*, *Drogownictwo* **7-8** (2016), 240–245.
- [38] J. Gajda, M. Mielczarek, *Automatic vehicle classification in systems with single inductive loop detector*, *Metrology and Measurement Systems* **21** (2014), Nr 4, 619–630.
- [39] J. Gajda, R. Sroka, *Vehicle classification by parametric identification of the measured signals*, *Proceedings of XVI IMEKO World Congress (Vienna)*, vol. IX, 2000, 199–204.
- [40] J. Gajda, R. Sroka, M. Stencel, T. Zeglen, P. Piwowar, P. Burnos, Z. Marszalek, *Design and accuracy assessment of the multi-sensor weigh-in-motion system*, 2015 IEEE International Instrumentation and Measurement Technology Conference (I2MTC), 2015, 1036–1041.
- [41] Janusz Gajda, Piotr Burnos, Ryszard Sroka, *Weigh-in-motion systems for direct enforcement in poland*, *Proceedings of the 7th International Conference on Weigh-In-Motion (ICWIM 7)*, 2016.
- [42] Janusz Gajda, Ryszard Sroka, Piotr Burnos, Mateusz Daniol, *Weigh-in-motion site for type approval of vehicle mass enforcement systems in poland*, *Sensors* **23** (2023), Nr 22, 9290.
- [43] Zheng Ge, Songtao Liu, Feng Wang, Zeming Li, Jian Sun, *Yolox: Exceeding yolo series in 2021*, arXiv preprint arXiv:2107.08430 (2021).

Bibliografia

- [44] A. Gonzales, A. T. Papagiannakis, E. O'Brien, *Evaluation of an artificial neural network technique applied to multiple sensor weigh-in-motion systems*, Transportation Research Record Journal of the Transportation Research Board (2003), Nr 1855, 151–159.
- [45] S. V. Hernandez, A. Tok, S. G. Ritchie, *Integration of weigh-in-motion (wim) and inductive signature data for truck body classification*, Transportation Research Part C **68** (2016), 1–21.
- [46] ITS Polska, *Kdp-v dokumentacja - gitlab*, <https://gitlab.com/its-polska/kasi/wim/docs/kdp-v>, Dostęp: 29 sierpnia 2024 r.
- [47] B. Jacob, L. M. Cottineau, *Weigh-in-motion for direct enforcement of overloaded commercial vehicles*, Transportation Research Procedia **14** (2016), 1413–1422.
- [48] Bernard Jacob, Eugene O'Brien, S Jehaes, *COST 323: Weigh-in-motion of Road Vehicles - Final report*, Raport techniczny, LCPC, Paris, 2002.
- [49] A. Janota, V. Šimák, J. Hrbček, *Development of a weight-in-motion measurement system with an optical sensor*, Transport Systems Telematics (J. Mikulski, ed.), Communications in Computer and Information Science, vol. 715, Springer, 2017, 234–247.
- [50] Z. Jia, K. Fu, M. Lin, *Tire-pavement contact-aware weight estimation for multi-sensor wim systems*, Sensors **19** (2019), Nr 2027, 13.
- [51] Daehyeon Kim, Rodrigo Salgado, Adolph Altschaeffl, *Effects of supersingle tire loadings on pavements*, Journal of Transportation Engineering **131** (2005), Nr 10, 732–743.
- [52] E. Klein, E. Purson, D. Simon, G. Gentil, *High-speed weigh-in-motion road test in france*, Proceedings of 7th International Conference on Weigh-in-Motion, 2016, 152–161.
- [53] Aleksander Konior, Tomasz Konior, Krzysztof Brzozowski, Andrzej Maczyński, Artur Ryguła, *New functionalities of the weigh-in-motion system - iwim solution*, Transport Problems 2022: XIV International Scientific Conference; XI International Symposium of Young Researchers: conference proceedings (Katowice) (A. Śladkowski, ed.), Silesian University of Technology. Faculty of Transport and Aviation Engineering, Wydawnictwo Politechniki Śląskiej, 2022, Pamięć CD.
- [54] _____, *New functionalities of the weigh-in-motion system: iwim solution*, Transport Problems **18** (2023), Nr 2, 162–170, Accessed: August 29, 2024.

Bibliografia

- [55] Aleksander Konior, Paweł Piwowarczyk, Tomasz Konior, Artur Ryguła, *Assessment of possibilities to distinguish vehicles on the basis of wheel load characteristics*, Transport Systems Telematics (TST 2020), Springer, Cham, 2020, 272–284.
- [56] Tomasz Konior, Jacek Izydorczyk, *Identyfikacja pojazdów w ruchu miejskim*, 15–18, Wydawnictwo Politechniki Śląskiej, 2021.
- [57] ———, *The possibility of using induction loops as a source of information on vehicles*, 96–105, Wydawnictwo Politechniki Śląskiej, 2023.
- [58] Tomasz Konior, Jacek Izydorczyk, Artur Ryguła, Leonardo Guerson, *Addressing the reliability challenges of high-speed wim (hs-wim) for direct enforcement*, Technology Convergence 2023: Setting the Wheels In Motion: Reimagining the Future of Heavy Vehicles, Roads and Freight, Trinity College Dublin, 2023, 1–10.
- [59] T. M. Kwon, *Signal processing of piezoelectric weight-in-motion systems*, Conference Paper, 2007, https://www.researchgate.net/publication/262326600_Signal_processing_of_piezoelectric_weight-in-motion_systems.
- [60] Taek Kwon, *Signal processing of piezoelectric weight-in-motion systems*, Conference: Proceedings of the Fifth IASTED International Conference on Circuits, Signals and Systems, 07 2007, 233–238.
- [61] J. J. Lamas-Seco, P. M. Castro, A. Dapena, F. J. Vazquez-Araujo, *Vehicle classification using the discrete fourier transform with traffic inductive sensors*, Sensors **15** (2015), 27201–27214.
- [62] José J. Lamas-Seco, Paula M. Castro, Adriana Dapena, Francisco J. Vazquez-Araujo, *Vehicle classification using the discrete fourier transform with traffic inductive sensors*, Sensors **15** (2015), 27201–27214.
- [63] J. Lan, Y. Xiang, L. Wang, Y. Shi, *Vehicle detection and classification by measuring and processing magnetic signal*, Measurement **44** (2011), 174–180.
- [64] Joshua J Levy, A. James O'Malley, *Don't dismiss logistic regression: the case for sensible extraction of interactions in the era of machine learning*, BMC Medical Research Methodology **20** (2020), Nr 171.
- [65] H. Li, H. Dong, L. Jia, M. Ren, *Vehicle classification with single multi-functional magnetic sensor and optimal mns-based cart*, Measurement **55** (2014), 142–152.

Bibliografia

- [66] H. X. Liu, J. Sun, *Length-based vehicle classification using event-based loop detector data*, *Transportation Research Part C* **38** (2014), 156–166.
- [67] Scott M. Lundberg, Gabriel Erion, Hugh Chen, Alex DeGrave, Jordan M. Prutkin, Bala Nair, Ronit Katz, Jonathan Himmelfarb, Nisha Bansal, Su-In Lee, *From local explanations to global understanding with explainable ai for trees*, *Nature Machine Intelligence* **2** (2020), Nr 1, 2522–5839.
- [68] Scott M Lundberg, Su-In Lee, *A unified approach to interpreting model predictions*, *Advances in Neural Information Processing Systems 30* (I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, R. Garnett, eds.), Curran Associates, Inc., 2017, 4765–4774.
- [69] Z. Marszalek, T. Zeglen, R. Sroka, J. Gajda, *Inductive loop axle detector based on resistance and reactance vehicle magnetic profiles*, *Sensors* **18** (2018), Nr 14.
- [70] Zbigniew Marszalek, Krzysztof Duda, Piotr Piwowar, Marek Stencel, Tadeusz Zeglen, Jacek Izidorczyk, *Load Estimation of Moving Passenger Cars Using Inductive-Loop Technology*, *Sensors* **23** (2023), Nr 4, 2063 (en).
- [71] Zbigniew Marszalek, Tadeusz Zeglen, Ryszard Sroka, Janusz Gajda, *Inductive loop axle detector based on resistance and reactance vehicle magnetic profiles*, *Sensors* **18** (2018), Nr 7, 2376.
- [72] Trevor McGuire, *On the effectiveness of moving averages*, <https://trevormcguire.medium.com/on-the-effectiveness-of-moving-averages-fb31b0c1ab6f>, 2020, Accessed: 2024-08-31.
- [73] Ricardo Melo, Paulo Pereira, *Risk-based analysis for pavement management*, *Journal of Transportation Engineering* **138** (2012), Nr 4, 555–561.
- [74] Michał Mielczarek, *Estymacja indywidualnej prędkości pojazdu na podstawie analizy profilu magnetycznego.*, *Przegląd elektrotechniczny* **1** (2015), Nr 3, 188–191 (pl).
- [75] Luz Elena Y. Mimbela, Lawrence A. Klein, *A summary of vehicle detection and surveillance technologies used in intelligent transportation systems*, Raport techniczny, The Vehicle Detector Clearinghouse, Southwest Technology Development Institute, New Mexico State University, Las Cruces, NM, 2007, Funded by the Federal Highway Administration's Intelligent Transportation Systems Program Office.

Bibliografia

- [76] A. H. Mosa, K. Kyamakya, R. Junghans, M. Ali, F. Al Machot, M. Gutmann, *Soft radial basis cellular neural network (srb-cnn) based robust low-cost truck detection using a single presence detection sensor*, *Transportation Research Part C* **73** (2016), 105–127.
- [77] Najwyższa Izba Kontroli, *Ruch pojazdów przeciążonych na obszarach zurbanizowanych*, 2021, Dostęp: 05.2021.
- [78] NeuroCar, *Neurocar - systemy automatycznego rozpoznawania i analizy obrazu*, <https://neurocar.pl/?lang=pl>, Dostęp: 29 sierpnia 2024 r.
- [79] ———, *Pro ncar sys wim 04 - neurocar*, <https://neurocar.pl/nsproduct/pro-ncar-sys-wim-04/?lang=en>, Accessed: August 29, 2024.
- [80] Widi Nugraha, Indra Djati Sidi, *Probability-based evaluation of vehicular bridge load using weigh-in-motion data*, *Journal of Engineering and Technological Sciences* **48** (2016), Nr 1, 66–85.
- [81] Yan Pei, Swarnendu Biswas, Donald S. Fussell, Keshav Pingali, *An elementary introduction to kalman filtering*, arXiv preprint arXiv:1710.04055 (2017).
- [82] R. Quinley, *Wim data analyst's manual*, 2010, Accessed: 2024-09-13.
- [83] Leszek Rafalski, *Bezpieczeństwo ruchu drogowego w polsce ze szczególnym uwzględnieniem pojazdów ciężkich*, Konferencja „Bezpieczeństwo w transporcie drogowym i kolejowym” (Warszawa), 2012, 23 października 2012 r.
- [84] Randall D. Reese, Anna T. Quach, *Yolo for radio frequency signal classification*, Raport techniczny INL/CON-23-73981-Revision-0, Idaho National Laboratory, May 2024, Prepared for the U.S. Department of Energy under DOE Idaho Operations Office Contract DE-AC07-05ID14517, 24A1081-049FP.
- [85] L. Rutkowski, *Filtry adaptacyjne i adaptacyjne przetwarzanie sygnałów*, WNT, Warszawa, 1994.
- [86] A. Ryguła, T. Konior, P. Piwowarczyk, *Classification method for vehicles with a maximum permissible weight up to 3.5 tonnes*, *Archives of Transport System Telematics* **12** (2019), Nr 4, 27–30.
- [87] Artur Ryguła, Aleksander Konior, Paweł Piwowarczyk, Leszek Kornalewski, *Assessment of the possibility of using selected statistic tools for testing long-term stability of weigh in motion systems*, *Transport System Telematics* **11** (2018), Nr 4, 1–10.

Bibliografia

- [88] Dariusz Ryś, Jerzy Judycki, Piotr Jaskuła, *Analiza rocznych zmian w ruchu ciężkim na podstawie danych ze stacji ważenia pojazdów*, Drogownictwo (2014), Nr 11.
- [89] ———, *Wpływ pojazdów przeciążonych na trwałość nawierzchni asfaltowych*, Logistyka (2014), Nr 6.
- [90] Dawid Ryś, *Obciążenie dróg przez pojazdy ciężkie i ich wpływ na trwałość zmęczeniową konstrukcji nawierzchni podatnych i półsztywnych (loading of roads by heavy vehicles and their impact on fatigue life of flexible and semi-rigid pavement structures)*, Phd thesis, Gdańsk University of Technology, Gdańsk, Poland, 2015, Promotor: prof. dr hab. inż. Józef Judycki, Promotor pomocniczy: dr inż. Piotr Jaskuła.
- [91] R. Samer et al., *Classification and speed estimation of vehicles via tire detection using single-element piezoelectric sensor*, Journal of Advanced Transportation **50** (2016), 1366–1385.
- [92] K.J. Shinohara, G. Otto, V.Z. Tani, F. De Mori, A.M. Valente, *Brazilian piaf model and the direct enforcement project*, Proceedings of the 7th International Conference on Weigh-In-Motion (ICWIM 7), 2016.
- [93] M Sivagami, A Vaishali, Ramya Ramakrishnan, A Subasini, *Weather prediction model using savitzky-golay and kalman filters*, Procedia Computer Science **165** (2020), 449–455.
- [94] Swarco, *Weigh in motion systems - swarco*, <https://www.swarco.com/mobility-future/intelligent-transportation-systems/weigh-motion-systems>, Accessed: August 29, 2024.
- [95] G. Thompson, K. Kroll, C. Grangroth, J. Arnold, *Wim sensor performance and stability across time periods and variations in temperature*, Proceedings of the 8th International Conference on Weigh-In-Motion (ICWIM 8), 2019.
- [96] University of Michigan, *Principal component analysis (pca), independent component analysis (ica), and factor analysis (fa)*, 2014, Accessed: 2024-08-31.
- [97] Hans van Loo, Aleš Žnidarič, *Guide for users of weigh-in-motion: An introduction to weigh-in-motion*, International Society for Weigh-in-Motion (ISWIM), Switzerland, 2019, Accessed: August 29, 2024.
- [98] Bruno R. Vasconcellos, Marcelo Rudek, Marcelo De Souza, *A Machine Learning Method for Vehicle Classification by Inductive Waveform Analysis*, IFAC-PapersOnLine **53** (2020), Nr 2, 13928–13932 (en).

Bibliografia

- [99] Shifeng Wang, Sarath Kodagoda, Lei Shi, Hualin Wang, *Road-terrain classification for land vehicles: Employing an acceleration-based approach*, IEEE Vehicular Technology Magazine **12** (2017), Nr 3, 34–41, Authorized licensed use limited to: Politechnika Slaska.
- [100] WELMEC, *Welmec guide 7.2: Software guide*, 2018, Accessed: 2024-09-13.
- [101] Indika Wickramasinghe, Harsha Kalutarage, *Naive bayes: applications, variations and vulnerabilities: a review of literature with code snippets for implementation*, Soft Computing **25** (2020), Nr 3, 2277–2293.