



**AGH**

AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE

**DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH**

DYSCYPLINA AUTOMATYKA, ELEKTRONIKA, ELEKTROTECHNIKA  
I TECHNOLOGIE KOSMICZNE

## **ROZPRAWA DOKTORSKA**

**Algorytmy kalibracji i auto-kalibracji sensorów radarowych  
dla systemów aktywnego bezpieczeństwa i jazdy  
autonomicznej**

Autor: mgr inż. Rafał Michał Burza

Promotor rozprawy: dr hab. inż. Krzysztof Duda, prof. AGH  
Promotor pomocniczy: dr hab. inż. Dariusz Borkowski

Praca wykonana: Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii  
Biomedycznej

Kraków, 2024



*Pragnę wyrazić serdeczne podziękowania:*

*Panu dr hab. inż. Krzysztofowi Dudzie, prof. AGH, oraz  
Panu dr hab. inż. Dariuszowi Borkowskiemu za wyrozumiałość i nieocenione wsparcie na każdym etapie doktoratu.*

*Angelice za nieustające wsparcie we wszystkich, nawet najtrudniejszych pomysłach.*

*Rodzicom za wsparcie, trud włożony w moje wychowanie oraz gotowość do niesienia pomocy we wszystkich trudnościach.*

*Dziadkom, całej rodzinie i przyjaciołom za wszystko, co bezcenne i nie sposób wymienić.*



# Abstract

Radars play a crucial role in advanced driver assistance systems (ADAS) and autonomous driving by providing critical information about the vehicle's surroundings. Their advantage lies in the ability to simultaneously measure the distance and radial velocity of objects within the field of view. As the functionality offered by automotive systems becomes increasingly sophisticated, the demands placed on sensors providing input to these systems also escalate. Many sensors introduced to the market offer high measurement precision; however, their integration within a network of cooperating sensors requires precise information regarding their position and orientation to align the measurements within a common coordinate system.

Despite the careful installation of sensors on the vehicle during assembly, deviations in sensor orientation are inevitable due to the inherent inaccuracies of the manufacturing process. To minimize such errors, it is necessary to employ sensor calibration in the factory, often referred to as static calibration or end-of-line alignment, which not only corrects the small deviations that are unavoidable but also alerts line operators if the vehicle fails to meet quality standards.

The methods used within the production line or automotive workshop are insufficient to ensure proper sensor orientation once the vehicle is in the hands of the user. For complex driver assistance systems, which may be sensitive to radar measurement errors, it is essential to provide continuous monitoring of the sensor's condition to respond to changes in orientation caused by collisions or the gradual aging of the radar's mounting bracket. This task is carried out by radar auto-calibration algorithms, also known as dynamic alignment algorithms.

Most solutions found in the literature focus on adjusting the horizontal misalignment angle of the radar from the expected value using static, dynamic, and post-factum calibration algorithms. Some methods also enable the assessment of the vertical misalignment angle, which can affect the incorrect assessment of object traversability, radar range, and negatively impact the quality of radar detections. However, no solution in the literature allows for displacement correction across all three axes.

The first innovation introduced in this dissertation is the improvement of the static radar calibration algorithm, based on a calibration target known in the literature – a steel plate. Due to its properties, the estimation of the radar's orientation angle can be performed by placing the steel plate in front of the radar and precisely tilting the plate towards the ground and the ceiling. The collected measurements of the reflected radar wave power as a function of the steel plate's tilt angle can be approximated using a second-degree polynomial. The maximum of the found polynomial corresponds to the plate's tilt angle at which the radar wave was reflected perpendicularly to the radar. This allows for determining the radar's tilt in elevation with high precision. Horizontal radar tilt is more challenging because the azimuth measurement often contains

outlier values that cannot be correlated with other radar data. For this reason, the algorithm was enhanced with an iterative method, specifically a robust mean. The calibration process, improved in this way, has been patented and implemented in production.

Another method proposed by the author is the improvement of dynamic calibration, which in previously used methods included tilts in the horizontal and vertical axes. A mathematical model was proposed, which, in the case of radars capable of measuring the elevation angle, allows for the inclusion of the radar's third axis of rotation during detection correction, as well as a model allowing for the algorithmic estimation of radar orientation errors in all three axes. Various optimizers were presented, which can be used for the iterative determination of the desired tilt angles, and then tested on synthetic data and compared using the proposed quality indicators. The proposed algorithm has also been submitted in the form of a patent.

The third developed method is a post-factum three-axis calibration designed to estimate the three-axis orientation error of the radar, even when the radar does not have the capability to measure elevation. The method is based on generating random elevation angles with a designed distribution in the detections, which, with sufficient computational power and memory to use several hundred detections during each iteration, can serve to perform three-axis estimation. For this purpose, the nonlinear method of total least squares was utilized. The estimated tilt angles determined by this method were used to correct real detections from the open RadarScenes dataset. The results of the quality indicators confirmed that the three-axis correction of detections by the determined angles reduces the root-mean-square error of the real detections.

# Streszczenie

Radary odgrywają kluczową rolę w zaawansowanych systemach wspomagania kierowcy oraz jazdy autonomicznej, zapewniając informacje o otoczeniu pojazdu. Ich zaletą jest możliwość jednoczesnego pomiaru odległości oraz prędkości radialnej obiektów w polu widzenia. Wraz z rosnącym zaawansowaniem funkcjonalności oferowanych przez systemy samochodowe, rosną wymagania stawiane sensorom, które dostarczają do nich informacji wejściowych. Wiele czujników wprowadzanych na rynek oferuje wysoką precyzję pomiarów, jednak ich współdziałanie w ramach współpracującej sieci sensorów wymaga precyzyjnej informacji o ich położeniu i orientacji, która pozwoli na sprowadzenie pomiarów do wspólnego układu współrzędnych.

Pomimo starannego montażu czujników na samochodzie podczas instalacji elementów na linii produkcyjnej zawsze pojawiają się odchylenia w orientacji sensora spowodowane niedokładnościami procesu montażu. Aby zminimalizować takie błędy, konieczne jest stosowanie kalibracji sensorów w fabryce, nazywanej również statyczną kalibracją lub adiustacją na końcu linii produkcyjnej, która pozwala nie tylko na korektę małych odchyżeń, które są nieuniknione, ale także na zasygnalizowanie operatorom linii, że pojazd nie spełnia wymagań jakościowych.

Stosowane w ramach linii produkcyjnej czy warsztatu samochodowego metody nie są w stanie zapewnić właściwej orientacji czujników po otrzymaniu samochodu przez użytkownika. W przypadku złożonych systemów wspomagania kierowcy, które mogą być wrażliwe na błędy pomiarowe radaru, konieczne jest zapewnienie stałego monitorowania stanu sensora, tak aby reagować na zmiany orientacji spowodowane kolizjami lub powolnym starzeniem się uchwyty montażowego radaru. Zadanie to realizowane jest przez algorytmy auto-kalibracji radaru, nazywane również algorytmami dynamicznej adiustacji.

Większość rozwiązań obecnych w literaturze skupia się na adiustacji horyzontalnego kąta przekrzywienia radaru od wartości oczekiwanej, za pomocą algorytmów kalibracji statycznej, dynamicznej i post-factum. Niektóre metody umożliwiają również ocenę wertykalnego kąta przekrzywienia, który może prowadzić do niepoprawnej oceny przejezdności obiektów, ograniczenia zasięgu radaru i negatywnego wpływu na jakość detekcji radarowych. Jednakże, żadne rozwiązanie w literaturze nie pozwala na uwzględnienie przemieszczenia we wszystkich trzech osiach.

Pierwszą z innowacji wprowadzonych w tej rozprawie jest udoskonalenie algorytmu statycznej kalibracji radaru, bazującego na znanym w literaturze celu kalibracyjnym – stalowej płycie. Ze względu na jej właściwości estymacja kąta orientacji radaru może być dokonana poprzez umiejscowienie stalowej płyty przed radarem i precyzyjne pochylanie płyty w kierunku ziemi i sufitu. Zebrane w ten sposób pomiary mocy odbitej fali radarowej w funkcji kąta wychylenia stalowej płyty mogą być aproksymowane wielomianem drugiego stopnia. Maksimum znalezionej wielomianu odpowiada kątowi wychylenia płyty, w którym

fala radarowa odbiła się pod kątem prostym do radaru. Pozwala to na wyznaczenie przekrzywienia radaru w elewacji z dużą precyzją. Horyzontalne przekrzywienie radaru sprawia trudności, ponieważ pomiar azymutu często zawiera wartości odstające, których nie da się skorelować z innymi danymi radarowymi. Z tego względu algorytm został wzbogacony o metodę iteracyjną, jaką jest średnia odporna. Udoskonalony w ten sposób proces kalibracji został opatentowany i wdrożony do produkcji.

Kolejną metodą zaproponowaną przez autora jest udoskonalenie dynamicznej kalibracji, która w dotychczas stosowanych metodach obejmowała przekrzywienia w osiach horyzontalnej i wertykalnej. Zaproponowano model matematyczny, który w przypadku radarów zdolnych do pomiaru kąta elewacji, pozwala na uwzględnienie trzeciej osi obrotu radaru podczas korekcji detekcji, a także model, pozwalający na algorytmiczne estymowanie błędów orientacji radaru w trzech osiach. Przedstawiono różne optymalizatory, które mogą być wykorzystane do iteracyjnego wyznaczenia poszukiwanych kątów przekrzywienia, a następnie przetestowano je na danych syntetycznych i porównano przy użyciu zaproponowanych wskaźników jakości. Zaproponowany algorytm został również zgłoszony w formie patentu.

Trzecią opracowaną metodą jest trójosiowa kalibracja post-factum, zaprojektowana do estymacji trójosiowego błędu orientacji radaru, nawet gdy radar nie posiada możliwości pomiaru elewacji. Metoda opiera się na generowaniu losowych kątów elewacji z zaprojektowaną dystrybucją w detekcjach, które przy mocy obliczeniowej i pamięci wystarczającej na użycie kilkuset detekcji w trakcie każdej iteracji, są w stanie posłużyć do trójosiowej estymacji. Do tego celu wykorzystano nieliniową metodę całkowitych najmniejszych kwadratów. Kąty estymowanego przekrzywienia, wyznaczone przez nią, posłużyły do korekcji rzeczywistych detekcji z otwartego zbioru danych RadarScenes. Wyniki wskaźników jakości potwierdziły, że trójosiowa korekta detekcji wyznaczonymi kątami redukuje błąd średniokwadratowy rzeczywistych detekcji.

# Spis treści

<b>Spis rysunków</b>	<b>xiii</b>
<b>Skróty</b>	<b>xix</b>
<b>Spis symboli i oznaczeń</b>	<b>xxiii</b>
<b>Słownik terminów</b>	<b>xxix</b>
<b>1 Wstęp</b>	<b>1</b>
1.1 Tematyka . . . . .	1
1.2 Teza badawcza . . . . .	3
1.3 Udokumentowany wkład badawczy . . . . .	3
1.4 Konspekt dokumentu . . . . .	4
<b>2 Kluczowe kierunki rozwoju przemysłu motoryzacyjnego</b>	<b>7</b>
2.1 Rys historyczny . . . . .	7
2.2 Analiza i wnioski . . . . .	12
<b>3 Zaawansowane systemy wspomagania kierowcy</b>	<b>15</b>
3.1 Estymacja stanu pojazdu . . . . .	16
3.2 Obserwacja kabiny i otoczenia . . . . .	16
3.3 Systemy ADAS i współpraca z kierowcą . . . . .	18
3.4 Komunikująca się sieć transportowa . . . . .	19
<b>4 Jazda autonomiczna</b>	<b>25</b>
4.1 Poziomy autonomiczności . . . . .	25
4.2 Architektura systemów AD . . . . .	27
4.2.1 Warstwa percepcji . . . . .	28
4.2.2 Warstwa decyzyjna . . . . .	29
4.2.3 Warstwa wykonawcza . . . . .	29
4.3 Błędy systemów AD . . . . .	30
4.3.1 Błąd percepcji . . . . .	30
4.3.2 Błąd decyzji . . . . .	31
4.3.3 Błąd akcji . . . . .	31

4.4	Potencjał jazdy autonomicznej . . . . .	31
4.5	Wyzwania jazdy autonomicznej . . . . .	32
<b>5</b>	<b>Multisensoryczna fuzja danych w zastosowaniach samochodowych</b>	<b>35</b>
5.1	Model fuzji danych „Joint Directors of Laboratories” (JDL) . . . . .	38
5.1.1	Wzbogacanie obiektów . . . . .	40
5.1.2	Wzbogacenie sytuacji . . . . .	44
5.2	Architektury fuzji danych . . . . .	46
5.2.1	Architektura scentralizowana . . . . .	47
5.2.2	Architektura rozproszona . . . . .	48
5.2.3	Architektura hybrydowa . . . . .	49
5.2.4	Inne architektury fuzji . . . . .	49
5.3	Wyzwania algorytmów fuzji multisensorycznej . . . . .	49
<b>6</b>	<b>Radary w motoryzacji</b>	<b>53</b>
6.1	Anteny radarowe . . . . .	54
6.2	Fala ciągła z modulowaną częstotliwością . . . . .	56
6.3	Przetwarzanie sygnału w radarach FMCW . . . . .	59
6.3.1	Mapa odległości i prędkości radialnej . . . . .	59
6.3.2	Kąt nadejścia . . . . .	60
6.3.3	Wykrywanie celów . . . . .	60
6.3.4	Klasyfikacja obiektów . . . . .	61
6.3.5	Śledzenie obiektów . . . . .	61
<b>7</b>	<b>Optymalizacja w kalibracji radarów</b>	<b>63</b>
7.1	Metody bezgradientowe . . . . .	66
7.1.1	Metoda Hooke’a–Jeevesa . . . . .	66
7.1.2	Metoda sympleks Nelder–Meada . . . . .	69
7.2	Metody gradientowe . . . . .	71
7.2.1	Metoda największego spadku . . . . .	71
7.2.2	Metoda nieliniowa najmniejszych kwadratów . . . . .	72
7.2.3	Metoda nieliniowa całkowitych najmniejszych kwadratów . . . . .	73
<b>8</b>	<b>Kalibracja i autokalibracja radarów samochodowych</b>	<b>75</b>
8.1	Fizyczne metody adiustacji . . . . .	76
8.2	Algorytmiczne metody kalibracji . . . . .	76
8.2.1	Statyczna kalibracja . . . . .	77
8.2.2	Dynamiczna kalibracja . . . . .	79
8.2.3	Kalibracja na torze . . . . .	81
8.2.4	Kalibracja post-factum . . . . .	81
8.3	Wpływ błędu kąta montażowego na systemy ADAS i AD . . . . .	82

8.3.1	Całkowite lub częściowe przysłonięcie czujnika . . . . .	82
8.3.2	Spadek maksymalnego zasięgu . . . . .	84
8.3.3	Rozróżnialność celów od szumu . . . . .	86
8.3.4	Przemieszczenie detekcji i utrata pokrycia w obszarach zainteresowania . . . . .	88
8.3.5	Niedokładności wektora prędkości celu . . . . .	90
8.3.6	Problemy z asocjacją danych . . . . .	95
8.3.7	Lokalizacja i mapowanie . . . . .	97
<b>9</b>	<b>Opracowane metody kalibracji radaru</b>	<b>101</b>
9.1	Kalibracja statyczna za pomocą wychylanej płyty . . . . .	103
9.2	Dynamiczna trójosiowa adiustacja radaru z kompensacją prędkości . . . . .	108
9.3	Trójosiowa kalibracja post-factum z kompensacją prędkości . . . . .	111
<b>10</b>	<b>Dane</b>	<b>113</b>
10.1	Automatyczna weryfikacja danych testowych . . . . .	114
10.1.1	Architektura sieci walidacyjnej . . . . .	114
10.1.2	Uzyskane wyniki sieci walidacyjnej . . . . .	118
10.2	Otwarte zbiory danych radarowych . . . . .	121
10.3	Dane syntetyczne . . . . .	122
<b>11</b>	<b>Ewaluacja opracowanych metod</b>	<b>123</b>
11.1	Wybrane kluczowe wskaźniki jakości . . . . .	123
11.1.1	Liczba iteracji do pokonania 95% dystansu do optimum . . . . .	124
11.1.2	Maksymalne odchylenie od wartości optymalnej . . . . .	124
11.1.3	Średnia kwadratowa residuów prędkości radialnej . . . . .	124
11.1.4	Skośność . . . . .	125
11.1.5	Kurtoza . . . . .	125
11.2	Metoda odniesienia . . . . .	125
11.2.1	Wybór detekcji stacjonarnych . . . . .	125
11.2.2	Metoda optymalizacji w algorytmie referencyjnym . . . . .	126
11.3	Wyniki trójosiowej kalibracji post-factum z kompensacją prędkości na danych rzeczywistych	130
11.4	Wyniki uzyskane na danych syntetycznych . . . . .	133
11.4.1	Dynamiczna trójosiowa adiustacja z kompensacją prędkości - metoda największego spadku . . . . .	134
11.4.2	Dynamiczna trójosiowa adiustacja z kompensacją prędkości - nieliniowa metoda najmniejszych kwadratów . . . . .	136
11.4.3	Dynamiczna trójosiowa adiustacja z kompensacją prędkości - nieliniowa metoda całkowitych najmniejszych kwadratów . . . . .	138
11.4.4	Dynamiczna trójosiowa adiustacja z kompensacją prędkości - metoda sympleksu Nelder-Meada . . . . .	140
11.5	Analiza wyników . . . . .	142

<b>12 Podsumowanie</b>	<b>145</b>
12.1 Wnioski . . . . .	147
12.2 Potencjalne kierunki rozwoju . . . . .	148

# Spis rysunków

2.1	Test zderzeniowy NCAP 32 - Ford Pinto. Kolizja w tył samochodu powoduje eksplozję paliwa. Kadr z filmu [30]. . . . .	10
2.2	Test zderzeniowy NCAP 14391 - Ford Ranger XL Supercab [42]. . . . .	11
4.1	Przykład działania warstw architektury systemu AD. Cel (żółty) wykonuje manewr niebezpieczny (trajektoria szara), system ocenia hipotezy trajektorii i po odrzuceniu prowadzących do kolizji (czerwone), wybiera najbezpieczniejszą (zielona), która zostanie wykonana. . . .	28
5.1	Podstawowa zasada działania fuzji danych. Sensory dostarczają dane, które są przetwarzane i łączone w zunifikowane wyjście. Inspirowane [145]. . . . .	35
5.2	Przykład intersekcji obszarów niepewności. Czerwony i niebieski prostopadłością symbolizują przedziały niepewności pomiaru dwóch urządzeń. Zielony obszar jest ich częścią wspólną. Inspirowane [146]. . . . .	37
5.3	Model JDL. Ilustracja zainspirowana przez [149]. . . . .	39
5.4	Zaktualizowany model JDL do zastosowań motoryzacyjnych. Ilustracja zainspirowana przez [149]. . . . .	39
5.5	Uproszczony schemat architektury centralnej, podzielonej na obszary obliczeń realizowanych przez procesory sensorów i ECU. Inspirowane [146]. . . . .	47
5.6	Uproszczony schemat architektury rozproszonej, podzielonej na obszary obliczeń realizowanych przez procesory sensorów i ECU. Inspirowane [146]. . . . .	48
5.7	Uproszczony schemat architektury hybrydowej, podzielonej na obszary obliczeń realizowanych przez procesory sensorów i ECU. Przerwane linie oznaczają opcjonalne połączenie, które może zostać zredukowane na etapie projektowania. Inspirowane [146]. . . . .	48
6.1	Przykładowe obszary zastosowania radarów w systemach ADAS. Ilustracja inspirowana [155].	54
6.2	Przykładowy szyk antenowy wraz z ilustracją formowania wiązki. Sterowane opóźnienie sygnału antenowego $\varphi$ , opóźnia czoła fali pojedynczych anten w szyku (przerwana linia), sterując kierunkiem wynikowej wiązki radarowej (czerwona linia). Ilustracja inspirowana [156]. . . . .	55
6.3	Schemat ilustrujący zasadę działania anten wirtualnych. Fala pod kątem $\zeta$ powraca z drogą dłuższą o odcinek zależny od odległości pomiędzy antenami nadawczymi ( $d$ ), co umożliwia zmierzenie sygnałów o przesunięciu w czasie w stosunku do sygnału referencyjnego. Ilustracja inspirowana [159]. . . . .	56

6.4	Schemat anten nadawczych (czerwone pola) i odbiorczych (niebieskie pola) w szyku antenowym, który przy użyciu technologii MIMO skutkuje powstaniem szyku wirtualnego (pola zielone). Inspirowane [157] oraz [158]. . . . .	57
6.5	Wykres sygnału częstotliwości przedstawiający przykładowy sygnał referencyjny FMCW (linia niebieska) i oczekiwaną częstotliwość fali powracającej (czerwona przerywana linia). Inspirowane [160]. . . . .	57
6.6	Uproszczony schemat radaru FMCW z trzema antenami nadawczymi i czterema antenami odbiorczymi. Inspirowane [160]. . . . .	58
6.7	Schemat przetwarzania sygnału w radarach FMCW. Inspirowane [160]. . . . .	59
7.1	Mapa poziomicowa przykładowej funkcji celu z minimum lokalnym z lewej strony oraz minimum globalnym z prawej. Ciemniejsze obszary oznaczają mniejsze wartości. Czerwona linia oznacza kierunek optymalizacji lokalnej równania z wartością początkową oznaczoną kropką. . . . .	63
7.2	Etapy wykonywania przykładowego algorytmu optymalizacji globalnej narysowane na mapie poziomicowej. Ciemniejsze obszary oznaczają mniejsze wartości. Czerwone kropki przedstawiają populacje rozwiązań. . . . .	65
7.3	Przykładowa zbieżność algorytmu Hooke'a-Jeevesa. Czerwone kropki oznaczają kolejne pozycje punktu bazowego. Linia ciągłą oznaczono przemieszczenie punktu bazowego $\mathbf{b}_{hj}^B$ , linią przerywaną przemieszczenie punktu $\mathbf{b}$ podczas zakończonych sukcesem kroków w etapie roboczym. . . . .	67
7.4	Schemat blokowy algorytmu Hooke'a-Jeevesa. Inspirowany [161]. . . . .	68
7.5	Symplex stosowany w metodzie Nelder-Meada (niebieski), wraz z przedstawieniem środka ciężkości z wyłączeniem najgorszego punktu $\bar{\mathbf{b}}$ oraz potencjalnych nowych punktów zastępujących $\mathbf{b}_3$ na etapach: odbicia $\mathbf{b}_r$ , ekspansji $\mathbf{b}_e$ , zwężenia zewnętrznego $\mathbf{b}_{oc}$ , wewnętrznego $\mathbf{b}_{ic}$ oraz redukcji $\mathbf{b}_z$ . . . . .	70
7.6	Porównanie metody najmniejszych kwadratów i całkowitych najmniejszych kwadratów. Punkty pomiarowe oznaczono okręgami. Czerwona linia oznacza dopasowany model, a przerywana minimalizowaną odległość. Inspirowane [164]. . . . .	72
8.1	Maksymalna odległość bezpośredniej detekcji dla radaru na wysokości $h = 0,5$ [m] i maksymalnym zasięgu $R_{FoV} = 100$ [m]. . . . .	82
8.2	Radar przekrzywiony wertykalnie w kierunku ziemi. Jasnoniebieski obszar pokazuje moc transmisji radaru odbitą od ziemi. Ciemnoniebieska linia pokazuje ścieżkę fali odbitej (ciągłą) oraz postrzeganą ścieżkę fali z detekcją widzianą przez czujnik (przerywana). Czerwona przerywana linia pokazuje niewyrównaną detekcję postrzeganą przez system, który nie jest świadomy przekrzywienia. . . . .	83

8.3	Radar przekrzywiony wertykalnie w kierunku nieba. Jasnoniebieski obszar obrazuje moc transmisji radaru. Ciemnoniebieska linia oznacza ścieżkę fali radarowej powodującą detekcję. Czerwona przerywana linia pokazuje niewyrównaną detekcję postrzeganą przez system, który nie jest świadomy przekrzywienia. . . . .	84
8.4	Stosunek pomiędzy transmitowaną a odbieraną mocą spowodowaną kierunkowym zyskiem anten w elewacji, przy założeniu, że anteny nadawcze i odbiorcze mają te same kąty montażu i pozycje oraz obserwują ten sam cel. . . . .	85
8.5	Odebrana moc odbicia od samochodu (czerwony obszar) i dorosłego pieszego (niebieski obszar). Przerywane linie przedstawiają minimalny poziom mocy wymagany do osiągnięcia detekcji dla prawidłowo zamontowanego radaru (czerwona linia przerywana) oraz radaru przekrzywionego wertykalnie o 10 stopni (niebieska linia przerywana). . . . .	86
8.6	Obliczone wartości średnie szumu miejskiego dla radarów o rozdzielczości pomiaru odległości 0,75 [m] oraz 0,25 [m]. Parametry użytego radaru: wysokość nad ziemią ( $h$ )—0,4 [m], szerokość wiązki w azymucie ( $\theta_{az}$ )—90 [°], współczynnik kształtu wiązki ( $\alpha_c$ )—1 oraz częstotliwość radaru - 15 [GHz]. . . . .	88
8.7	Potencjalny scenariusz błędnej klasyfikacji pasa ruchu i wizualizacja martwego pola przednich radarów z zaznaczonym polem widzenia czujników (niebieski obszar), krawędziami pola widzenia (przerywane linie) oraz osiami zwrotu sensora (czarna linia). . . . .	90
8.8	Kąt przekrzywienia, który spowodowałby błędne przypisanie celu punktowego do niewłaściwego pasa ruchu w funkcji odległości. . . . .	91
8.9	Długość dwusiecznej obszaru martwego pola widzenia dla kątów montażu przednich radarów: 45 [°] (niebieski), 60 [°] (pomarańczowy), 65 [°] (złoty). . . . .	91
8.10	Wpływ kąta przekrzywienia radaru wynoszącego 1 [°] na błąd kierunku celu dla prędkości celu równej prędkości pojazdu ego (niebieski) oraz dla prędkości pojazdu ego dwukrotnie większej niż prędkość celu (czerwony). . . . .	94
8.11	Wpływ kąta przekrzywienia radaru wynoszącego 7 [°] na błąd kierunku celu dla prędkości celu pięciokrotnie większej niż prędkość pojazdu ego (niebieski) oraz dla kąta przekrzywienia 1 [°] przy prędkości pojazdu ego dwudziestokrotnie większej niż prędkość celu. . . . .	94
8.12	Funkcja gęstości prawdopodobieństwa (FGP) błędów kierunku celu dla wyrównanego i przekrzywionego radaru stworzona na podstawie symulacji. Parametry użyte w symulacji Monte Carlo: odchylenie standardowe – 2 [°], szerokość celu obserwowana przez radar — 30 [°], $T - 10e^{j\pi}$ [m/s], $V - 20e^{j0}$ [m/s], liczba realizacji pomiaru – $10^8$ . . . . .	97
8.13	Funkcja gęstości prawdopodobieństwa (FGP) błędów kierunku celu dla wyrównanego i przekrzywionego radaru stworzona na podstawie symulacji. Użyte parametry takie jak w symulacji z rysunku 8.12, z wyjątkiem położenia centrum celu $\alpha_{VCS} = -135$ [°]. . . . .	98
8.14	Prawdopodobieństwo nieprawidłowego podziału obiektów w symulowanym scenariuszu dla celu obserwowanego pod kątami w układzie współrzędnych samochodu. . . . .	98

9.1	Ilustracja przedstawiająca schemat stanowiska kalibracyjnego przedniego prawego sensora w fabryce. Samochód prowadzony po linii produkcyjnej jest pozycjonowany tak, aby bezpośrednio przed nim znajdowała się stalowa płyta, której wychylenie w elewacji może być precyzyjnie kontrolowane przez serwomechanizm. . . . .	103
9.2	Uproszczony schemat procesu kalibracyjnego dla parametrów: $K$ - liczba detekcji pobieranych podczas jednego wychylenia płyty, $N$ - liczba kroków w orientacji płyty, $M$ - liczba losów do estymacji wariancji uzyskanych estymat. . . . .	104
9.3	Schemat obrazujący działanie statycznej kalibracji za pomocą wychylanej płyty. Radar (z lewej) przekrzywiony w górę o kąt $\beta_m$ obserwuje maksymalną amplitudę detekcji, gdy płyta (z prawej) jest wychylona o kąt $\beta_{fp}$ w kierunku podłoża. Strzałki wskazują kąt zaczepiony w zerze i zwrócony w kierunku dodatnim dla pochylenia radaru (niebieski) i płyty (czerwony). Kąt dodatni oznacza pochylenie obiektu w kierunku podłoża. . . . .	105
9.4	Ilustracja prezentująca przykładowy przebieg pomiarów z wychylanej wertykalnie płyty. Kolory rozróżniają detekcje pochodzące z kolejnych orientacji celu. . . . .	106
9.5	Ilustracja przedstawiająca wpływ przekrzywienia radaru na detekcje radarowe. Czerwone punkty przedstawiają detekcje radarowe naniesione na układ współrzędnych samochodu nieświadomego przekrzywienia radaru, zielone punkty oznaczają skorygowane detekcje, niebieskie strzałki oznaczają wektor korygujący detekcje. . . . .	108
10.1	Schemat dwóch zaproponowanych sieci walidacyjnych. Wspólne elementy zostały przedstawione kolorem niebieskim, element użyty w przypadku sieci estymującej prędkość kolorem żółtym, a element użyty w przypadku sieci do klasyfikacji anomalii kolorem zielonym. . . . .	115
10.2	Schemat architektury bloku wstępnego przetwarzania detekcji w zaproponowanej walidacyjnej sieci neuronowej. . . . .	116
10.3	Schemat architektury bloku kompresji przestrzennej w zaproponowanej walidacyjnej sieci neuronowej. . . . .	116
10.4	Schemat architektury bloku przetwarzania informacji przestrzennej w zaproponowanej walidacyjnej sieci neuronowej. . . . .	117
10.5	Schemat architektury bloku końcowego przetwarzania w celu uzyskania estymaty prędkości liniowej i obrotowej pojazdu. . . . .	117
10.6	Schemat architektury bloku końcowego przetwarzania w celu detekcji i klasyfikacji anomalii. . . . .	118
10.7	Funkcja gęstości prawdopodobieństwa błędu prędkości pojazdu wyestymowanej za pomocą zaproponowanej sieci neuronowej. . . . .	119
10.8	Funkcja gęstości prawdopodobieństwa błędu prędkości obrotowej pojazdu wyestymowanej za pomocą zaproponowanej sieci neuronowej. . . . .	119
10.9	Macierz błędu dla sieci walidacyjnej. Klasy: 0 - dane z zaburzoną prędkością radialną, 1 - dane z zaburzoną prędkością pojazdu, 2 - dane z zaburzoną prędkością obrotową pojazdu, 3 - dane bez wprowadzonego błędu. . . . .	120

11.1	Ilustracja przedstawiająca początkowe dane wejściowe dla algorytmu wyboru detekcji stacjonarnych (kolor niebieski), wybrane detekcje (kolor pomarańczowy) oraz oczekiwana krzywą detekcji stacjonarnych (kolor złoty). Detekcje radarowe pochodzące z RadarScenes—Sekwencja 1. . . . .	126
11.2	Ilustracja przedstawiająca zbieżność do wartości optymalnej znalezionej przez algorytm estymacji błędu kąta montażowego dla każdego czujnika, przeprowadzona na podstawie detekcji radarowych ze zbioru danych RadarScenes—Sekwencja 1. . . . .	127
11.3	Funkcja gęstości prawdopodobieństwa (FGP) odchyień prędkości radialnej od modelu, skumulowana dla wszystkich radarów zamontowanych na pojeździe. Czujniki celowo wychylone o wartości $\alpha_m$ : 3, -3, -2, -1 [°] (kolor niebieski), oryginalne kąty montażu (kolor pomarańczowy) oraz prawidłowo wyrównane czujniki (kolor złoty). RadarScenes—Sekwencja 1 . . . . .	128
11.4	Ilustracja przedstawiająca zbieżność do wartości optymalnej $k_v$ znalezionej przez algorytm post-factum. RadarScenes—Sekwencja 1. . . . .	130
11.5	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\alpha_m$ znalezionej przez algorytm post-factum. RadarScenes—Sekwencja 1. . . . .	131
11.6	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\beta_m$ znalezionej przez algorytm post-factum. RadarScenes—Sekwencja 1. . . . .	131
11.7	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\gamma_m$ znalezionej przez algorytm post-factum. RadarScenes—Sekwencja 1. . . . .	131
11.8	Ilustracja przedstawiająca zbieżność do wartości optymalnej $k_v$ znalezionej przez algorytm gradientowy największego spadku. . . . .	134
11.9	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\alpha_m$ znalezionej przez algorytm gradientowy największego spadku. . . . .	134
11.10	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\beta_m$ znalezionej przez algorytm gradientowy największego spadku. . . . .	135
11.11	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\gamma_m$ znalezionej przez algorytm gradientowy największego spadku. . . . .	135
11.12	Ilustracja przedstawiająca zbieżność do wartości optymalnej $k_v$ znalezionej przez nieliniową metodę najmniejszych kwadratów. . . . .	136
11.13	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\alpha_m$ znalezionej przez nieliniową metodę najmniejszych kwadratów. . . . .	136
11.14	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\beta_m$ znalezionej przez nieliniową metodę najmniejszych kwadratów. . . . .	137
11.15	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\gamma_m$ znalezionej przez nieliniową metodę najmniejszych kwadratów. . . . .	137
11.16	Ilustracja przedstawiająca zbieżność do wartości optymalnej $k_v$ znalezionej przez nieliniową metodę całkowitych najmniejszych kwadratów. . . . .	138

11.17	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\alpha_m$ znalezionej przez nieliniową metodę całkowitych najmniejszych kwadratów. . . . .	138
11.18	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\beta_m$ znalezionej przez nieliniową metodę całkowitych najmniejszych kwadratów. . . . .	139
11.19	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\gamma_m$ znalezionej przez nieliniową metodę całkowitych najmniejszych kwadratów. . . . .	139
11.20	Ilustracja przedstawiająca zbieżność do wartości optymalnej $k_v$ znalezionej przez algorytm sympleksu Nelder-Meada. . . . .	140
11.21	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\alpha_m$ znalezionej przez algorytm sympleksu Nelder-Meada. . . . .	140
11.22	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\beta_m$ znalezionej przez algorytm sympleksu Nelder-Meada. . . . .	141
11.23	Ilustracja przedstawiająca zbieżność do wartości optymalnej $\gamma_m$ znalezionej przez algorytm sympleksu Nelder-Meada. . . . .	141
11.24	Algorytmy: 1D - Referencyjny, NS - największego spadku, NLS - nieliniowy najmniejszych kwadratów, TLS - nieliniowy całkowitych najmniejszych kwadratów, NM - sympleks Nelder-Meada. . . . .	143

# Skróty

- ABS** *Anti-lock Brake System*. Przeciwblokujący układ hamulcowy.. 18, 28
- ACC** *Adaptive Cruise Control*. Aktywny tempomat.. 18, 55
- AD** *Autonomous Driving*. Jazda autonomiczna.. ix, x, xiii, 1–3, 26–28, 30–33, 54, 82
- ADAS** *Advanced Driver-Assistance System*. Zaawansowane systemy wspierania kierowcy.. ix, x, 1–3, 17, 18, 29, 54, 81, 82, 89
- ADC** *Analog-Digital Converter*. Przetwornik analogowo-cyfrowy.. 59
- AEB** *Autonomous Emergency Braking*. Autonomiczne hamowanie awaryjne.. 53
- BAS** *Brake Assistance Systems*. Systemy wspomaganie hamowania.. 18
- BSD** *Blind Spot Detection*. System wykrywania pojazdów w martwym polu widzenia.. 55
- C2C-CC** *CAR 2 CAR Communication Consortium*. Konsorcjum dążące do udoskonalenia wydajności i bezpieczeństwa pojazdów poprzez opracowanie innowacyjnych metod komunikacji.. 20
- CA** *Constant Acceleration (Model)*. Model ruchu zakładający stałe przyspieszenie pojazdu.. 41
- CASS** *Cooperative Active Safety System*. System kooperacyjnego aktywnego bezpieczeństwa, który działając na informacji z sensorów, estymatorów oraz komunikacji V2V ma zwiększyć bezpieczeństwo pojazdów.. 23
- CCCW** *Cooperative Collision Warning System*. System ostrzegania o potencjalnej kolizji, bazujący na danych GPS i komunikacji V2V.. 22
- CMOS** *Complementary Metal-Oxide-Semiconductor*. Technologia wytwarzania układów scalonych składających się z tranzystorów MOS.. 53
- CT** *Coordinated Turn (Model)*. Model ruchu zakładający stałą prędkość oraz prędkość obrotową (skręcanie) pojazdu.. 41
- CTA** *Cross Traffic Assist*. Układ wspomagający wyjazd na skrzyżowaniu dróg.. 55
- CV** *Constant Velocity (Model)*. Model ruchu zakładający stałą prędkość pojazdu.. 41

- DSC** *Dynamic Stability Control*. Układ dynamicznej kontroli stabilności.. 19, 28
- DSRC** *Dedicated Short Range Communication*. Dedykowana komunikacja krótkiego zasięgu, jeden ze standardów komunikacji pomiędzy pojazdami korzystający z pasma 5.9 GHz. 20, 21, 23
- ECU** *Electronic Control Unit*. Elektroniczna jednostka sterująca.. xiii, 1, 29, 47–49, 77, 81, 102
- ECWA** *Early Collision Warning Avoidance*. System ostrzegania o potencjalnej kolizji bazujący na fuzji danych z GPS i czujników oraz komunikacji V2V.. 22
- EOL** *End Of the Line*. Proces przeprowadzany na końcu linii produkcyjnej.. 3, 76, 77
- ESP** *Electronic Stability Program*. System elektronicznej stabilizacji toru jazdy.. 18, 28
- FCA** *Forward Collision Avoidance*. System unikania kolizji czołowych. 18, 29
- FCC** *Federal Communications Commission*. Amerykańska agencja regulująca zasady wykorzystania częstotliwości radiowych dla celów związanych z komunikacją. 20
- FCM** *Forward Collision Mitigation*. System ograniczania skutków kolizji czołowej.. 18, 29
- FCW** *Forward Collision Warning*. System ostrzegania przed kolizją czołową.. 18, 55
- FFT** *Fast Fourier Transform*. Szybka transformacja Fouriera.. 57, 58, 60, 102
- FGP** Funkcja gęstości prawdopodobieństwa.. xv, xvii, 97, 98, 128
- FMCW** *Frequency-Modulated Continuous-Wave*. Technologia polegająca na generowaniu ciągłej fali radarowej z modulowaną częstotliwością.. x, xiv, xxvii, xxix, 4, 56–59
- GPS** *Global Positioning System*. System Nawigacji Satelitarnej umożliwiający określenie położenia użytkownika.. 21–23, 28, 29, 35, 37, 43, 44
- ISO** *International Organization for Standardization; International Standards Organisation*. Organizacja pozarządowa zrzeszająca krajowe organizacje normalizacyjne. 10
- ITS** *Intelligent Transportation Systems*. Inteligentne systemy transportowe.. 20, 21, 23, 28
- JDL** *Model Joint Directors of Laboratories*. Model fuzji opracowany w 1985 roku przez zespół ds. fuzji danych grupy U.S. Joint Directors of Laboratories.. x, xiii, 38–40, 44
- KPI** *Key Performance Indicators*. Kluczowe wskaźniki jakości.. 127–130, 132, 133, 135, 137, 139, 141, 142, 148
- LCA** *Lane-Change Aid/Assist*. System wspomaganie zmiany pasa ruchu.. 18
- LKA** *Lane-Keeping Aid/Assist*. System wspomaganie utrzymania pasa ruchu.. 18

- MMIC** *Monolithic Microwave Integrated Circuit*. Monolityczny mikrofalowy układ scalony.. 53
- NCAP** *New Car Assessment Program*. Program oceny nowych samochodów w kontekście bezpieczeństwa pojazdów. Istnieje wiele organizacji regionalnych zajmujących się testowaniem nowych pojazdów np. Euro NCAP, NHTSA's NCAP.. xiii, 10, 11, 54
- NHTSA** *National Highway Traffic Safety Administration*. Urząd ds. bezpieczeństwa ruchu drogowego USA.. xxi, 26
- PA** *Park Aid/Assist*. System wspomagania parkowania.. 18
- PACT** *Pilot Authorisation and Control of Task*. Struktura autoryzacji i kontroli zadań pilota. Szczegółowy dokument definiujący rolę automatyzacji i pilota w autonomicznych systemach.. 26
- RCS** *Radar Cross Section*. Skuteczna powierzchnia odbicia celu radarowego.. 61, 83, 85, 88, 114
- RCW** *Rear Collision Warning*. System ostrzegania o nadchodzącej tylniej kolizji.. 55
- RMSE** *Root Mean Square Error*. Średnia kwadratowa błędów.. 124, 128–130, 132, 135, 137, 139, 141
- RSC** *Roll Stability Control*. System zapobiegający przewróceniu się pojazdu.. 18, 28
- SAE** *Society of Automotive Engineers*. Zawodowa organizacja skupiająca inżynierów zajmujących się motoryzacją, lotnictwem i maszynami wykorzystywanymi w przemyśle.. 8–10
- TCS** *Traction Control System*. System kontroli trakcji.. 18, 28
- V2I** *Vehicle-to-Infrastructure*. Komunikacja pomiędzy pojazdem a elementami inteligentnej infrastruktury drogowej.. 19, 20
- V2V** *Vehicle-to-Vehicle*. Komunikacja pomiędzy dwoma pojazdami.. 19, 20
- VANET** *Vehicular ad-hoc network*. Spontanicznie tworzone sieci bezprzewodowe do zastosowań samochodowych.. 20
- VCS** *Vehicle Coordinate System*. Układ współrzędnych pojazdu. Z reguły posiada on punkt zerowy w środku tylnej osi pojazdu. Oś X, przebiega przez środek pojazdu w kierunku jego przodu.. xxiii, xxiv, 2
- WAVE** *Wireless Access in Vehicular Environments*. Standard definiujący sieć krótkiego zasięgu na potrzeby ITS.. 20



# Spis symboli i oznaczeń

- ° Stopień jako jednostka miary kąta płaskiego. Używany w tej pracy ze względu na częste operowanie na małych wartościach.. xv, xvii, 82, 88, 91, 94, 97, 98, 103, 112, 121, 124, 128–130, 132–141
- $A_c$  Powierzchnia oświetlona przez impuls radarowy.. 87
- $A_{fp}$  Amplituda fali elektromagnetycznej odbitej od stalowej płyty.. xxvi, 105–107
- $A_g$  Parametr A modelu szumu otoczenia.. 87
- $\alpha_b$  Oczekiwana horyzontalna orientacja radaru.. 90–92, 98, 109, 127
- $\alpha_c$  Współczynnik kształtu impulsu radarowego.. xv, 87, 88
- $\alpha_{FOV}$  Rozpiętość kątowa horyzontalnego pola widzenia.. 90
- $\alpha_{fp}$  Kąt pod którym widziana jest stalowa płyta.. 107
- $\hat{\alpha}_n$  Skorygowana wartość pomiaru horyzontalnego kąta detekcji.. 89
- $\alpha_m$  Wartość kątowa horyzontalnego błędu montażowego.. xvii, xviii, 89–95, 98, 107, 109–112, 122, 124, 125, 127–143
- $\alpha_n$  Horyzontalny kąt detekcji radarowej.. 89, 91, 92, 98, 109, 110, 122, 127
- $\alpha_{VCS}$  Horyzontalny kąt detekcji w układzie VCS.. 90–92, 109–112, 122
- $B$  Szerokość pasma.. 57
- $\mathbf{b}$  Wektor optymalizowanych parametrów.. xiv, xxiv, 63, 64, 67, 69–72, 124
- $\mathbf{b}^{(n)}$  Wartość optymalizowanego wektora parametrów w momencie  $n$ .. 66, 71–73, 110, 111
- $b$  Pojedynczy element wektora optymalizowanych parametrów np.  $i$ -ty  $b_i$ .. xxiii, 71, 73, 106, 107
- $\mathbf{b}^{(n+1)}$  Wartość optymalizowanego wektora parametrów w momencie  $n + 1$ .. 66, 71, 73, 110, 111
- $B_g$  Parametr B modelu szumu otoczenia.. 87
- $B_L$  Dwusieczna martwego pola widzenia pomiędzy dwoma radarami.. 90

$\Delta \mathbf{b}_{hj}$  Zbiór wektorów poszukiwań w metodzie Hooke'a Jeevesa.. 66, 67

$\beta_{FoV}$  Wertykalna rozpiętość kątowna pola widzenia radaru.. 82

$\beta_{fp}$  Wychylenie stalowej płyty w jej własnym układzie współrzędnych.. xvi, 105, 106

$\hat{\beta}_n$  Skorygowana wartość pomiaru wertykalnego kąta detekcji.. 89

$\beta_m$  Wartość kątowna wertykalnego błędu montażowego.. xvi–xviii, 82, 89, 105–107, 109–112, 122, 124, 130–143

$\beta_n$  Wertykalny kąt detekcji radarowej.. 89, 109, 110, 112, 122

$\beta_{VCS}$  Wartość wertykalnego kąta detekcji w układzie VCS.. 109–112, 122

$\bar{\mathbf{b}}_{hj}^B$  Poprzedni punkt bazowy metody Hooke'a Jeevesa.. 67

$\mathbf{b}_{hj}^B$  Punkt bazowy metody Hooke'a Jeevesa.. xiv, 67

$\mathbf{b}^*$  Wartość optymalna wektora parametrów  $\mathbf{b}$ .. 63, 64, 124

$c_0$  Prędkość światła.. 57

$C_g$  Parametr C modelu szumu otoczenia.. 87

$D$  Kwadratowa odległość Mahalanobisa.. 96

$d$  Zdefiniowana odległość.. xiii, 56

$D_\alpha$  Granica asocjacji za pomocą kwadratowej odległości Mahalanobisa.. 96

$D_g$  Parametr D modelu szumu otoczenia.. 87

$\bar{D}_n$  Wektor kierunkowy  $n$ -tej detekcji.. 91, 92

$\Delta_b$  Przyrost wektora szukanych parametrów.. 66, 127

$\hat{\Delta}^{of}$  Oszacowana różnica między stanami obiektów.. 96

$\Delta f$  Różnica częstotliwości.. 57

$\Delta t$  Różnica czasu.. 41, 57

$\eta$  Współczynnik określający, jaka część wyestymowanego kroku ma zostać wykonana; współczynnik uczenia.. 71–73, 110–112, 127

$F$  Macierz przejścia w równaniu stanu.. 41

$f_{CT}$  Funkcja przejścia równania stanu w modelu skoordynowanego skreću.. 41

$G_r$  Zysk kierunkowy anteny odbiorczej.. 85

$G_t$  Zysk kierunkowy anteny nadawczej.. 85

$\gamma_m$  Kąt skręcenia radaru.. xvii, xviii, 109–112, 122, 124, 130–143

$G_{CT}$  Macierz wejść równania stanu.. 41

$h$  Wysokość montażu radaru nad poziomem nawierzchni drogowej.. xiv, xv, 82, 87, 88

$J$  Macierz Jacobiego.. 73, 110, 111

$K_r$  Liczba radarów.. 112

$k_v$  Współczynnik kompensacji prędkości radaru.. xvii, xviii, 109–112, 122, 124, 125, 127, 129, 130, 132–141

$\ell$  Funkcja celu (funkcja kosztów).. 63, 64, 66, 69–73

$\lambda$  Długość fali elektromagnetycznej.. 58, 85, 87

$\lambda_m$  Parametr Marquardt'a stosowany w metodzie najmniejszych kwadratów.. 110, 111

$\mu$  Współczynnik używany do operacji na punktach w algorytmie sympleksu Nelder-Meada. W zależności od etapu algorytmu, współczynnik ten może przyjąć wartości:  $\mu_{ic}$ ,  $\mu_{oc}$ ,  $\mu_r$ ,  $\mu_e$ .. 69

$\mu_r$  Współczynnik używany do redukcji w algorytmie sympleksu Nelder-Meada. xxv, 69

$\mu_e$  Współczynnik używany do ekspansji w algorytmie sympleksu Nelder-Meada. xxv, 69

$\mu_{ic}$  Współczynnik używany do zwężania wewnętrznego w algorytmie sympleksu Nelder-Meada. xxv, 69, 70

$\mu_{oc}$  Współczynnik używany do zwężania zewnętrznego w algorytmie sympleksu Nelder-Meada. xxv, 69, 70

$N_d$  Liczba detekcji.. 111

$\omega$  Rozważ użycie przecinka zamiast ukośnika, aby oddzielić dwie definicje bardziej przejrzysto: "Częstotliwość kołowa, prędkość kątowa.. 41

$P$  Macierz kowariancji.. xxv, 96

$P^f$  Kowariancja obiektu pochodzącego z algorytmu fuzji danych.. 96

$P^o$  Kowariancja zmierzonych stanów obiektu.. 96

$P^{of}$  Kowariancja różnicy stanów obiektu.. 96

$P_r$  Moc transmisji odebranej przez radar.. 85

- $P_t$  Moc transmisji wysłanej przez radar.. 85
- $\phi$  Orientacja obiektu.. 41, 98
- $\phi_{gr}$  Kąt natarcia fali radarowej.. 87
- $\varphi$  Przesunięcie fazowe.. xiii, 55, 56, 58
- $r$  Odległość detekcji radarowej.. 57, 58, 85, 87, 89, 98
- $\mathbf{R}$  Macierz residuów składająca się z elementów  $\left[ R_1 \quad R_2 \quad \dots \quad R_n \right]^T$  .. xxvi, 73, 110, 111, 127
- $R$  Residuum.. xxvi, 72
- $R_e$  Promień Ziemi.. 87
- $R_{FoV}$  Maksymalny zadeklarowany zasięg radaru.. xiv, 82
- $\overline{R_M}$  Wektor relatywnej prędkości samochodu, obrócony w kierunku detekcji w taki sposób, że  $\Re \{ \overline{R} \} = \dot{r}$ , obarczony błędem spowodowanym przekrzywieniem radaru.. 92, 93
- $R_{max}$  Maksymalna możliwa do zaobserwowania odległość detekcji od radaru.. 82
- $\mathbf{R}_{\dot{r}}$  Residuum  $\dot{r}$ .. 110, 111, 127
- $\overline{R_T}$  Wektor prawdziwej lub poprawnej relatywnej prędkości samochodu, obrócony w kierunku detekcji w taki sposób, że  $\Re \{ \overline{R} \} = \dot{r}$ .. 92, 93
- $\mathbf{R}_x$  Macierz rotacji wokół osi X.. 89
- $\mathbf{R}_y$  Macierz rotacji wokół osi Y.. 89
- $\mathbf{R}_z$  Macierz rotacji wokół osi Z.. 89
- $\dot{r}$  Prędkość radialna.. xxvi, 90–92, 109–112, 122, 124, 125
- $\rho$  Rozdzielczość pomiaru odległości.. 87
- $\sigma$  Odchylenie standardowe.. xxvi, 93, 107, 125, 128
- $\sigma_{A_p}^2$  Wariancja amplitudy fali elektromagnetycznej odbitej od stalowej płyty.. 107
- $\sigma_h$  Odchylenie standardowe nierówności powierzchni.. 87
- $\sigma_{RCS}$  Skuteczna powierzchnia odbicia celu radarowego.. 85, 87
- $\sigma_{RCS}^0$  Znormalizowana refleksyjność szumu otoczenia.. 87
- $\Sigma_{svd}$  Wartość macierzy  $\Sigma$  z dekompozycji SVD.. 73, 111, 127
- $\overline{T}$  Wektor prędkości celu.. 91–93

- $T_c$  Czas trwania chirpa w radarze *Frequency-Modulated Continuous-Wave*. Technologia polegająca na generowaniu ciągłej fali radarowej z modulowaną częstotliwością. (FMCW).. 57
- $T_{c,diff}$  Czas pomiędzy kolejnymi chirpami w radarze FMCW.. 58
- $\overline{T_M}$  Wektor prędkości celu, obarczony błędem spowodowanym przez przekrzywienie radaru.. 92, 93
- $\overline{T_T}$  Wektor poprawnej lub prawdziwej prędkości celu.. 92, 93
- $T_x$  Prędkość celu wzdłuż osi X.. 90, 125
- $T_y$  Prędkość celu wzdłuż osi Y.. 90, 125
- $\theta$  Kąt nadejścia (ang. *Angle-of-Arrival*).. 58
- $\theta_{az}$  Szerokość wiązki radarowej.. xv, 87, 88
- $\overline{V}$  Wektor prędkości samochodu ego.. 91–93
- $v$  Prędkość.. 41, 58
- $V_{\omega_x}$  Komponent prędkości samochodu wzdłuż osi wzdłużnej powstały w wyniku ruchu obrotowego pojazdu.. 109, 111, 112, 125, 127
- $V_{\omega_y}$  Komponent prędkości samochodu wzdłuż osi poprzecznej powstały w wyniku ruchu obrotowego pojazdu. Wykorzystywany zamiennie z  $V_y$ .. xxvii, 90, 109, 111, 112, 125, 127
- $U_{svd}$  Wartość macierzy  $U$  z dekompozycji SVD.. 73, 111, 127
- $V_{svd}$  Wartość macierzy  $V$  z dekompozycji SVD.. 73, 111, 127
- $V_x$  Prędkość liniowa.. 90, 109–112, 125, 127
- $V_y$  Komponent prędkości samochodu wzdłuż osi poprzecznej powstały w wyniku ruchu obrotowego pojazdu. Wykorzystywany zamiennie z  $V_{\omega_y}$ .. xxvii
- $W_R$  Szerokość pasa jezdni.. 89
- $W_S$  Odległość pomiędzy dwoma radarami.. 90
- $w_k$  Szum procesu.. 41, 42
- $w_{\omega}$  Komponent szumu procesu związany z prędkością kątową.. 42
- $w_v$  Komponent szumu procesu związany z prędkością liniową.. 42
- $\hat{x}^f$  Stany obiektu pochodzącego z algorytmu fuzji danych.. 96
- $\hat{x}^o$  Stany zmierzonego obiektu.. 96

$\hat{x}$  Skorygowana pozycja obiektu wzdłuż osi X.. 89

$x$  Pozycja obiektu wzdłuż osi X.. 41, 89, 98

$\ddot{x}$  Druga pochodna położenia obiektu (przyspieszenie) wzdłuż osi X. 41

$\dot{x}$  Pochodna pozycji obiektu (prędkość) wzdłuż osi X.. 41

$\mathbf{X}_k$  Macierz stanu obiektu w momencie  $k$ .. 41

$\mathbf{X}_{k+1}$  Macierz stanu obiektu w momencie  $k + 1$ .. 41

$\hat{y}$  Skorygowana pozycja obiektu wzdłuż osi Y.. 89

$y$  Pozycja obiektu wzdłuż osi Y.. 41, 89, 98

$\hat{z}$  Skorygowana pozycja obiektu wzdłuż osi Z.. 89

$z$  Pozycja obiektu wzdłuż osi Z.. 89

# Słownik terminów

**chirp** Fala radarowa o modulowanej, narastającej lub opadającej częstotliwości, używana w radarach FMCW.. 56–60

**dataset** Zbiór danych. W kontekście tej pracy termin używany do określenia danych z radarów nagranych podczas jazd testowych.. 4, 121, 130, 133–138

**ego** Termin często używany w scenariuszach samochodowych, aby wskazać pojazd, który rozpatrujemy z perspektywy pierwszej osoby, na którym zamontowane są czujniki. Stosowany zamiennie z terminem host.. xv, xxvii, xxix, 46, 94, 96

**host** Dosłownie gospodarz. Określenie stosowane w kontekście pojazdu, na którym zamontowane są sensory, który często traktujemy z perspektywy pierwszej osoby. Stosowane zamiennie z terminem ego.. xxix, 90, 92

**misalignment** Odchylenie od oczekiwanej wartości pozycji i orientacji sensora.. 3, 105, 123, 130, 142

**outlier** Obserwacja odstająca od pozostałych elementów próby.. 3

**tracker** Algorytm wykorzystywany do śledzenia i estymacji stanu obiektu w czasie, najczęściej przy użyciu modelu matematycznego oraz jednego z wielu wariantów filtra Kalmana.. 102



# Rozdział 1

## Wstęp

### 1.1 Tematyka

Jazda autonomiczna (AD), początkowo traktowana jako zagadnienie, które można wdrożyć na przestrzeni dekady, okazała się najbardziej wymagającym wyzwaniem w dziedzinie motoryzacji. Technologia stale ewoluuje, aby wprowadzić pojazdy o piątym poziomie autonomiczności do powszechnego użytku. Aby to osiągnąć, producenci mikroprocesorów skupiają się na tworzeniu coraz potężniejszych jednostek obliczeniowych, które obejmują przyspieszanie sieci neuronowych oraz równoległe przetwarzanie złożonych algorytmów [1], [2]. Zapotrzebowanie na różnorodne funkcje w pojazdach osobowych przyspiesza wzrost złożoności systemów, zarówno pod względem liczby jednostek sterujących (ECU), jak i rozmiaru oprogramowania, stwarzając nowe wyzwania związane z inżynierią oprogramowania, cyberbezpieczeństwem oraz złożonością samego procesu rozwoju produktów [3]–[5].

Pojawiają się nowe projekty radarów, dążące do zmniejszenia rozmiaru i kosztów tych urządzeń. W tym celu badacze opracowują m.in. radary przeznaczone do zastosowań motoryzacyjnych z antenami zintegrowanymi w układzie scalonym [6]. Taki kierunek może doprowadzić do obniżenia kosztów produkcji oraz wymiarów sensorów, jednocześnie zachowując oczekiwaną wydajność. To z kolei może przyczynić się do większej dostępności zaawansowanych systemów wspomagania kierowcy (ADAS) dla społeczeństwa oraz umożliwić montaż większej liczby radarów w pojazdach.

Zwiększone pokrycie skanowania otoczenia pojazdu za pomocą czujników może zwiększyć kompleksowość systemu, umożliwiając działanie w każdych warunkach, lecz rozwój jazdy autonomicznej wymaga również przemyślanego projektowania infrastruktury drogowej. Pomimo tego, że czujniki i elektroniczne elementy wykonawcze zazwyczaj reagują szybciej niż kierowca, to odpowiednio przemyślana infrastruktura drogowa może zwiększyć zasięg percepcji, zmniejszając szansę na wystąpienie potrzeby gwałtownego hamowania, jednocześnie zwiększając komfort pasażerów [7].

Radary także ewoluują, poprzez nowe konstrukcje anten, które pomimo niewielkich rozmiarów potrafią określać zarówno kąty poziome, jak i pionowe [8]. Wzrost mocy obliczeniowej mikroprocesorów umożliwia przetwarzanie większej liczby danych z radarów i przekazywanie ich do jednostek sterujących pojazdem (ECU). Zapewnienie takiej funkcjonalności wymaga szybkiego połączenia pomiędzy czujnikiem a ECU,

co można osiągnąć między innymi dzięki protokołowi SOME/IP opartemu na sieci Ethernet, oferującemu przepustowość 100 [Mbit/s] z możliwością uzyskania do 1 [Gbit/s] [9].

Chociaż projekty sensorów stają się coraz bardziej złożone i poszerzają ich możliwości, to wciąż istnieje potrzeba monitorowania stanu sensorów i raportowania ich do systemu. Funkcjonowanie sensora może zostać zakłócone przez obiekt, który go zasłania. W przypadku sensorów narożnych, źle ustawiony lub pomalowany zderzak może utrudnić propagację fali radarowej lub ją zakrzywić. Producenci pojazdów powinni uwzględniać te aspekty podczas projektowania i montażu samochodów, aby minimalizować skutki przejścia fali przez materiał zderzaka. Podobne wyzwania mogą pojawić się również w trakcie eksploatacji pojazdu, gdy sensor jest zanieczyszczony błotem lub śniegiem. Ochrona systemu przed negatywnymi skutkami takich zdarzeń wymaga zaimplementowania algorytmicznych metod wykrywania przysłonięcia sensora [10].

Systemy AD i ADAS, które składają się z wielu sensorów, wymagają sprowadzenia ich pomiarów do wspólnego układu współrzędnych pojazdu (VCS), o początku, który znajduje się na środku tylnej osi pojazdu. Wymaga to dokładnych informacji o pozycji montażu sensora oraz kącie montażu. Dla niektórych sensorów dokładność horyzontalna może być lepsza niż 1 [°], spełniając tym samym wymagania dotyczące dokładności radarów w kontekście AD i ADAS, jednak dokładność kąta montażu, która wprowadza systematyczny błąd do wszystkich pomiarów z danego sensora, stanowi nadal wyzwanie. Choć producenci pojazdów mogą podejmować skomplikowane kroki w celu poprawy dokładności montażu, to wciąż wymaga on ciągłego procesu weryfikacji i korekty algorytmicznej. Problem narasta, gdy radar jest wymieniany w warsztacie, bez dostępu do specjalistycznego sprzętu. Przykładem może być wymiana radaru po kolizji lub awarii. W takim przypadku proces montażu może wprowadzić błędy znacznie większe niż te, wynikające z algorytmów wykrywania kąta przez radar, co negatywnie wpływa na dokładność systemu. Błędy położenia kąтового mogą również powstawać podczas typowego użytkowania pojazdu, na przykład w wyniku zużycia elementów mocujących lub wystąpienia niewielkich kolizji, które mogą wpłynąć na pozycję sensora lub zderzaka przed nim.

Szybki rozwój systemów ADAS oraz badania nad jazdą autonomiczną wymagają niezawodnych i precyzyjnych czujników, które dostarczą bogatych informacji o otoczeniu oraz zachowaniu innych użytkowników dróg. W praktyce nie jest możliwe zapewnienie idealnego kąta montażu sensora przez cały cykl jego życia. W przypadku radarów, nieprecyzyjny montaż może prowadzić do błędnych lub niedokładnych informacji o obiektach oraz problemów z algorytmem śledzenia lub obniżeniem mocy odbitej od celu. Problemy spowodowane przekrzywieniem czujnika mogą być minimalizowane na dwa sposoby: poprzez korektę niedokładnego kąta za pomocą wyestymowanej wartości lub poprzez informowanie innych komponentów systemu o potencjalnej degradacji czujnika, jeśli wykryty błąd kątowy wychodzi poza akceptowalny zakres.

Kąt montażu sensora jest jedną z konfigurowalnych wartości, która może być zmieniona bez ingerencji w jego fizyczne podzespoły. Niestety niemożliwe jest zapewnienie, że wartość zadana w konfiguracji radaru będzie zawsze poprawna. Ze względu na problemy wskazane wcześniej, niemożliwe do przewidzenia przemieszczenia sensora – spowodowane kolizjami – a także błąd ludzki, konieczne staje się kalibrowanie sensora. Idealny proces kalibracji powinien zniwelować wszelkie zniekształcenia percepcji radaru, które mogą być spowodowane geometrią zderzaka, zastosowaną farbą, wadami anten lub fizycznymi przemiesz-

zeniami. Co więcej działanie takiego algorytmu kalibracji powinno być możliwe w tle, podczas codziennej pracy radaru, bez potrzeby podłączania zewnętrznych urządzeń lub wykonywania dodatkowych procedur.

## 1.2 Teza badawcza

Możliwe jest zaimplementowanie algorytmu automatycznej kalibracji radaru, który bazując na punktowych detekcjach radarowych, spodziewanym kącie montażu sensora oraz informacji o kinematyce pojazdu, będzie w stanie wyznaczyć trójosiowy błąd kątowy montażu i wykorzystać go do korekty pomiarów przy zachowaniu złożoności obliczeniowej, pozwalającej na wykonanie algorytmu na wbudowanym procesorze radarowym.

## 1.3 Udokumentowany wkład badawczy

1. **Armin Talai, Rafał Burza i Sashi Praveen Kalli. „Radar System Calibration with Bistatic Sidelobe Compensation”.** US Patent 17,407,071 [11] (US202117407071A, CN115707991A, US20230056655A1, EP4137841A1).

W wyniku prowadzonych prac badawczych i wdrożeniowych udało się opracować algorytm statycznej kalibracji radaru, przeprowadzanej po montażu sensora. Jest to jeden z końcowych procesów produkcji samochodu, wykonywany na końcu linii produkcyjnej (EOL). W wyniku prac zaimplementowano unikalny algorytm minimalizacji wpływu prążków bocznych odbicia z celu kalibracyjnego na dokładność kalibracji. Usprawnienie to zostało opisane i opublikowane w formie patentu, wkładem własnym autora było opracowanie algorytmu filtracji outlierów, który jest głównym elementem wynalazku.

2. **Rafał Burza i Dariusz Borkowski. „Methods and Systems for Determining Alignment Parameters of a Radar Sensor”.** EP3907521A1 [12] (wraz z późniejszymi zmianami CN113608182A, EP3907522A2, US20210341599A1).

Głównym celem prowadzonych prac badawczych było opracowanie algorytmu automatycznej kalibracji radaru, która wykonywana na procesorze radarowym i bazująca na informacjach dostępnych dla radaru jest w stanie dokonać trójosiowej estymacji błędu kąta montażowego sensora. Opracowany algorytm został zaimplementowany w produkcie komercyjnym oraz opublikowany w formie patentu.

3. **Rafał Burza. „Overview of Radar Alignment Methods and Analysis of Radar Misalignment’s Impact on Active Safety and Autonomous Systems”.** Sensors 2024, 24, 4913. [13]

Wykonano kompleksowy przegląd wpływów przesunięcia kątowego radaru na systemy ADAS i AD. Wnioski zostały podparte podstawami teoretycznymi, symulacjami oraz przeprowadzonymi obliczeniami. Dokonano również kompleksowego przeglądu literatury, który posłużył do opisanie metod korekcji błędu montażu sensora. W ostatniej części publikacji zaproponowana została metoda odniesienia, wskaźniki jakości dla algorytmów adjustacji oraz zostały wyliczone kluczowe wskaźniki jakości, bazujące na otwartym zbiorze danych - RadarScenes.

#### 4. Rafał Burza. „Application of Neural Networks for Validation of Data Integrity in Large Automotive Radar Datasets”. SPA Conference 2023. [14]

Opracowano metodę oceny danych wejściowych, bazującą na głębokiej sieci neuronowej. Zastosowana metoda pozwoliła na wskazanie nagrań z jazd testowych, które mogą być uszkodzone lub zawierać niewiarygodne dane. Praca w formie artykułu została zgłoszona na konferencję SPA 2023.

## 1.4 Konspekt dokumentu

Niniejsza rozprawa doktorska została podzielona na segmenty mające na celu stopniowe wprowadzenie czytelnika w tematykę kalibracji i auto-kalibracji radarów. Pierwsza część, na którą składają się rozdziały 2-4 stanowi ogólne wprowadzenie do tematyki aktywnego bezpieczeństwa. Następna część złożona z rozdziałów 5-7 wprowadza czytelnika w bardziej szczegółowe zagadnienia dotyczące: fuzji multisensorycznej, radarów oraz metod optymalizacji. Oryginalne wyniki badań przedstawiono w rozdziałach 8-11, które są skupione wyłącznie wokół zagadnień związanych z algorytmami kalibracji oraz związanymi z nimi pracami.

Rozdział 2 przedstawia tło historyczne, umożliwiające zapoznanie się z historią przemysłu samochodowego oraz trendami, które da się w nim zauważyć na przestrzeni dziesięcioleci. Przedstawiony zarys historyczny jest użyty do analizy racjonalności badań naukowych w podjętej dziedzinie.

Rozdział 3 przybliży tematykę zaawansowanych systemów wspomagania kierowcy i wymienia najważniejsze systemy należące do tej kategorii. W rozdziale opisano zależności funkcjonalności od elementów wykonawczych i sensorów koniecznych do ich działania. Opisany jest także trend rozwoju systemów aktywnego bezpieczeństwa, jakim jest komunikująca się sieć transportowa.

Rozdział 4 wyjaśnia poziomy autonomii oraz architekturę systemów jazdy autonomicznej. Wyjaśnione są warstwy jazdy autonomicznej: percepcji, decyzyjna, wykonawcza i nadzorcza. Rozdział przedstawia również potencjalne błędy jakie mogą wystąpić podczas jazdy autonomicznej: błędy percepcji, decyzji i akcji. Omówiono również potencjalne korzyści oraz wyzwania stojące przed jazdą autonomiczną.

Rozdział 5 przybliży temat fuzji multisensorycznej, która jest podstawowym elementem jazdy autonomicznej oraz złożonych systemów aktywnego bezpieczeństwa. Poruszona tematyka przedstawia model fuzji danych i jego podstawowych elementów, do których należy wzbogacanie obiektów oraz wzbogacanie sytuacji. Omówione są stosowane architektury fuzji danych: scentralizowana, rozproszona i hybrydowa oraz wyzwania z jakimi muszą się mierzyć systemy fuzji.

Rozdział 6 ma na celu przybliżyć podstawowe zagadnienia z zakresu radarów stosowanych w przemyśle samochodowym. Omówiono w nim tematy związane z budową anten radarowych oraz przetwarzaniem sygnału w radarach wykorzystujących falę ciągłą z modulacją częstotliwościową (FMCW). Ta część rozprawy ma na celu wyjaśnienie podstaw teoretycznych, pozwalających na zrozumienie jak odebrany przez anteny sygnał radiowy zamienia się w wykryty obiekt widoczny z poziomu ECU.

Rozdział 7 stanowi przegląd popularnych metod optymalizacji, które są adekwatne do tematu rozprawy doktorskiej. Wyjaśnia on działanie metod bezgradientowych (Hooke’a-Jeevesa i sympleksu Nelderera-Meada) oraz metod gradientowych (największego spadku, nieliniowych najmniejszych kwadratów oraz nieliniowych całkowitych najmniejszych kwadratów). Opisane metody są później użyte w części praktycznej rozprawy doktorskiej.

Rozdział 8 składa się z dwóch części. W pierwszej dokonano kompleksowego przeglądu metod kalibracji i auto-kalibracji radarów. Opisane zostały fizyczne metody adiustacji oraz metody algorytmiczne jakimi są: statyczna i dynamiczna kalibracja, a także kalibracja na torze oraz kalibracja post-factum. W drugiej części przeprowadzono szczegółową analizę wpływów błędu orientacji radaru na systemy wspomaganie kierowcy oraz jazdy autonomicznej. W wyniku prac stworzono oryginalne wyprowadzenia wzorów oraz analizy wpływu przekrzywienia na:

- całkowite lub częściowe przysłonięcie czujnika (autorska analiza);
- spadek maksymalnego zasięgu (autorska analiza, w kontekście, który nigdy nie był rozważany w literaturze);
- rozróżnialność celu od szumu (autorska analiza, w kontekście, który nigdy nie był rozważany w literaturze);
- przemieszczenie detekcji (znane w literaturze);
- niedokładność wektora prędkości celu (na podstawie autorskich wyprowadzeń wzorów);
- problemy z asocjacją danych (udowodnione autorskimi symulacjami);
- lokalizacja i mapowanie (autorska analiza i wyprowadzenie).

Rozdział 9 zawiera opis opracowanych autorskich metod kalibracji:

- Opracowana metoda kalibracji statycznej za pomocą wychylanej stalowej płyty, która zawiera autorskie rozwiązanie problemu pomiarów odstających za pomocą iteracyjnej średniej odpornej. Rozwiązanie to zostało zgłoszone w formie kilku międzynarodowych wniosków patentowych [11] (US202117407071A, CN115707991A, US20230056655A1, EP4137841A1).
- Opracowana autorska trójosiowa kalibracja radaru z kompensacją prędkości, która jest bezpośrednio związana z tezą rozprawy doktorskiej i została zgłoszona w formie patentów [12] (EP3907521A1, CN113608182A, EP3907522A2, US20210341599A1).
- Metoda opracowana poza pierwotnie zakładanym planem doktoratu wdrożeniowego pozwalająca na trójosiową estymację błędu orientacji wraz z współczynnikiem kompensacji prędkości nawet w przypadku, gdy radar nie umożliwia pomiaru elewacji detekcji.

Rozdział 10 zawiera opis danych używanych podczas prac oraz zaproponowaną sieć neuronową o autorskiej architekturze, która może zostać użyta do wstępnej walidacji danych testowych, opublikowaną w [14]. W ostatniej części rozdziału opisana jest metoda wzbogacania danych z otwartego zbioru o syntetyczny pomiar kąta elewacji.

Rozdział 11 przedstawia zaproponowane przez autora kluczowe wskaźniki jakości, które pozwalają na ocenę poprawności działania algorytmów pomimo braku informacji na temat oczekiwanych kątów korekcji detekcji. W rozdziale zaproponowano również metodę odniesienia oraz przedstawiono uzyskane wyniki metod na danych rzeczywistych oraz syntetycznych.

---

Rozdział 12 zawiera podsumowanie przeprowadzonych prac, wnioski wraz argumentacją popierającą udowodnienie założonej tezy badawczej. Ostatnia część rozdziału zawiera potencjalne kierunki rozwoju w obrębie poruszonych w rozprawie tematów.

## Rozdział 2

# Kluczowe kierunki rozwoju przemysłu motoryzacyjnego

Dla zrozumienia kierunku rozwoju technologii pojazdów mechanicznych oraz oceny przydatności rozwijanych technologii warto zapoznać się z rysem historycznym oraz osiągnięciami technologicznymi, które udoskonalały tę dziedzinę technologii. Wzorce, które można zaobserwować na przestrzeni ponad stuletniej historii przemysłu motoryzacyjnego prezentują cechy, które są kluczowe dla końcowego odbiorcy i wskazują na obszary największego zainteresowania zarówno w przypadku dostosowania produktu do tych oczekiwań jak i na kluczowe obszary badawcze, które mają największy potencjał wdrożeniowy.

### 2.1 Rys historyczny

Od czasu wynalezienia prekursora samochodu przez Karla Benza w 1886 roku, na przestrzeni prawie pół wieku, zmiany w samochodach osobowych skupiały się przede wszystkim na dostosowaniu samochodu do możliwości człowieka. Przykładem tych zmian może być m.in. wprowadzenie pasów, które miały zapobiec wypadnięciu pasażerów z siedzeń [15]. Wczesne samochody były wyposażone w drążek sterowniczy przypominający ster żagłówki, takie rozwiązanie wymagało jednak użycia znacznej siły do sterowania pojazdem. W celu rozwiązania tego problemu wynaleziono układ sterowania podobny do kierownicy rowerów, później zastąpiony kierownicą podobną do stosowanych obecnie [16]. System hamowania w początkowym okresie polegał na stosowaniu dźwigni, która przyciskała drewniany błocek do jednego z kół w samochodzie. Rozwiązanie to było kłopotliwe dla operatora pojazdu ze względu na konieczność wykorzystania rąk zarówno do hamowania jak i kierowania pojazdem. Aby zwiększyć siłę, z jaką kierowca może hamować oraz zapewnić możliwość jednoczesnego sterowania, na przełomie XIX i XX wieku wprowadzono pedał hamulca [16].

Wczesne lata XX wieku owocowały również wprowadzeniem instrumentów pomiarowych oraz wskaźników do samochodów. Z powodu awaryjności ówczesnych konstrukcji wskaźnik poziomu oleju był jednym z pierwszych, które pojawiły się w samochodach. Kolejnym, który wymagał wprowadzenia z tego samego powodu, był wskaźnik ciśnienia wody. Trzecim wskaźnikiem udostępnionym kierowcom stał się prędkościomierz, który w początkowej fazie nie pomagał w utrzymaniu bezpiecznej prędkości, a jedynie

promował możliwości samochodu [16]. Pierwsze ograniczenia prędkości w Stanach Zjednoczonych pojawiły się w roku 1901 w stanie Connecticut, który wprowadził ograniczenie do 8 [mil/h] na obszarze miasta i 12 [mil/h] poza nim [17]. Po roku 1910 w pojazdach zaczęto montować tachometry oraz czujniki temperatury, które były umieszczane na radiatorach utrzymujących stałą temperaturę pracy silnika. Pomimo zastosowania wielu wskaźników ich umiejscowienie pozostawiało wiele do życzenia, nie pozwalając na wygodny odczyt z pozycji kierowcy.

W 1901 roku założono pierwszy związek branżowy – Verein Deutscher Motorfahrzeug-Industrieller (później nazywany Verband der Automobilindustrie) – mający na celu promowanie transportu oraz stanowiący reprezentację przemysłu przed rządem. Potrzeba ustanowienia wspólnych standardów produkcji zaowocowała utworzeniem w 1905 roku *Society of Automotive Engineers* (SAE). Pierwsze spotkanie SAE odbyło się w 1906 roku i od tego czasu publikowane są „SAE Transactions”. W 1910 ukazało się pierwsze opracowanie standardów pod tytułem „SAE Handbook of Standards and Recommended Practices” [16].

Początki przemysłu motoryzacyjnego wiązały się również ze znacznymi usprawnieniami procesów produkcji, do których przyczyniły się głównie dwa wydarzenia. W 1901 roku w fabryce jednego z pionierów przemysłu motoryzacyjnego – Ransoma Oldsa – wybuchł pożar, który zniszczył większość zakładu oraz wyprodukowanych prototypów. Jedynym egzemplarzem, który przetrwał był tzw. „Curved Dash”. Był niskobudżetowym projektem, który miał zapewnić popularyzację samochodów wśród generalnej populacji. Ransom Olds, ze względu na zakontraktowane dostawy, postanowił skupić się na produkcji kluczowych elementów. Pozostałe części zostały zamówione u poddostawców, a komponenty dostarczane przez nich były montowane w ostateczny produkt w fabryce Oldsa [18]. Ten model biznesowy okazał się na tyle skuteczny, że pozostaje standardem do dnia obecnego. Drugą kluczową zmianą w procesie produkcji było wprowadzenie pierwszej linii produkcyjnej, która znacząco zredukowała czas wytwarzania samochodu, zwiększając tym samym liczbę montowanych pojazdów [19].

W latach 20. XX wieku rozpoczął się okres, który zainicjował finalizowanie koncepcji samochodu do formy jaką znamy obecnie. Dźwignię zapłonu zaczęto montować przy kierownicy, na środku której pojawił się już przycisk klaksonu. Wprowadzono jasne oznaczenia i podpisy wskaźników, montowane przed kierowcami, w celu poprawy ich widoczności. W 1930 roku wprowadzone zostały pierwsze kierunkowskazy w postaci mechanicznych semaforów, które zostały zastąpione elektronicznymi po 1950 roku. W latach trzydziestych skupiono się na aerodynamice pojazdów, w celu zwiększenia ich szybkości, przy jednoczesnym zachowaniu odpowiednich wymiarów samochodów, tak by kierowca i pasażerowie mogli w nich wygodnie siedzieć. Jednym z opracowań, które ukształtowało wygląd samochodów, była książka autorstwa Wunibalda Kamma „Das Kraftfahrzeug” z 1936 roku, w której zawarł oczekiwane wymiary kabiny [20].

Po I wojnie światowej liczba wypadków rosła ze względu na coraz większą popularność samochodów. Pod koniec lat dwudziestych niemiecki psycholog Narziss Ach zwrócił uwagę na potrzebę wykorzystania psychologii i technologii, w celu zmniejszenia liczby wypadków na drogach [21]. Po kilku latach temat ten został również podniesiony w magazynie Forbes, który stwierdził, że należy poznać w jakim stopniu czynniki ludzkie wpływają na wypadki [22]. Te publikacje pozwalają sądzić, że technologia samochodów zaczęła osiągać dojrzałość jeszcze przed wybuchem II Wojny Światowej. Przeszto wprowadzać drastyczne

zmiany konstrukcyjne, które zmieniłyby postrzeganie samochodu, a zainteresowaniem zaczęły cieszyć się udoskonalenia, które mogłyby zwiększyć ich bezpieczeństwo.

Pod koniec lat czterdziestych XX wieku wprowadzono jedną z pierwszych technologii pasywnego bezpieczeństwa w samochodach. Było nią wprowadzenie miękkiego obicia na desce rozdzielczej przez dwa koncerny Tucker i Chrysler [16]. W kolejnych latach prowadzono badania nad zwiększeniem widoczności kierowcy oraz wprowadzono pierwsze technologie do badań nad zachowaniem ludzkiego ciała podczas wypadku (manekiny zderzeniowe, akcelerometry, kamery poklatkowe) [23]. W latach 1949-1950 amerykańscy producenci samochodów zaczęli wprowadzać do swoich modeli pasy bezpieczeństwa. W 1952 roku wynaleziono strefy wolnego zgniotu oraz klatkę bezpieczeństwa w obszarze kabiny. W tym okresie założono również wiele organizacji, które miały za zadanie poznanie czynników ludzkich, wpływających na wypadki oraz zapoczątkowanie badań w tej dziedzinie [16].

W latach sześćdziesiątych opracowano dwu- i trójwymiarowe manekiny stworzone na podstawie danych antropometrycznych. Wyniki tego opracowania zostały zdefiniowane w normie SAE J826 [24]. Pozwoliło to producentom na dostosowanie budowy samochodu tak, aby zapewnić kierowcy lepszą widoczność otoczenia oraz wskaźników w samochodzie. Na danych antropometrycznych została również zdefiniowana norma SAE J941, która określiła pole widzenia kierowcy [25]–[27] oraz norma SAE J834 definiująca widoczność zalecaną oraz widoczność na otoczenie za pojazdem [28]. W tym okresie wynaleziono kolejne technologie pasywnego bezpieczeństwa [29]:

- trzypunktowe pasy bezpieczeństwa;
- zagłówki, które minimalizują ryzyko urazu w przypadku uderzenia w tył pojazdu;
- składana kolumna kierownicza, która redukowała obrażenia klatki piersiowej podczas wypadku.

W latach siedemdziesiątych temat bezpieczeństwa samochodów stał się popularny w Stanach Zjednoczonych, ze względu na poważną wadę konstrukcyjną Forda Pinto – w przypadku silnego uderzenia w tył tego pojazdu bardzo często następowało zgniecenie baku, które powodowało rozprysk paliwa [31]–[33]. Eksplozję paliwa podczas jednego z testów przedstawia rysunek 2.1. Niebezpieczeństwo, z jakim wiązała się kolizja w tył pojazdu, zapoczątkowało starania nad poprawą widoczności świateł hamowania, w wyniku czego rozpoczęto badania nad wprowadzeniem centralnego, wysoko zamontowanego światła hamowania. Prowadzono również badania nad typami świateł przednich, ich skutecznością, optymalnym umiejscowieniem oraz minimalizacją oślepiania innych kierowców. Wprowadzone zostały pierwsze systemy ABS, które zapoczątkowały erę systemów aktywnego bezpieczeństwa. W celu lepszego zrozumienia zachowania ciała ludzkiego podczas wypadku opracowano trzy iteracje manekinów do testów zderzeniowych Hybrid, które posiadały akcelerometry umieszczone w różnych miejscach ciała [34]. Zwiększenie dostępności zaawansowanego sprzętu pomiarowego pozwoliło na badania nad regionami zainteresowania kierowcy za pomocą sprzętu do śledzenia oczu. Pozwoliło to między innymi na ocenę czasu, jaki kierowcy poświęcają na obserwację lusterek oraz spoglądanie na radio [35]. W tym dziesięcioleciu opracowano serie standardów i metod takich jak:

- *Head Injury Criteria* - kryteria oceny ran głowy [36];



Rysunek 2.1: Test zderzeniowy NCAP 32 - Ford Pinto. Kolidacja w tył samochodu powoduje eksplozję paliwa. Kadr z filmu [30].

- *Abbreviated Injury Scales* - skala oceny obrażeń [36];
- SAE J287 - standard określający zasięg rąk kierującego [37], [38];
- SAE J1139 - standaryzacja kierunku działania urządzeń sterujących [37], [39];
- SAE J1048 - standaryzacja symboli na desce rozdzielczej [40];
- ISO 2631 - metoda estymacji postrzeganego dyskomfortu spowodowanego wibracjami pojazdu [41].

Jedną z najbardziej znaczących zmian w podejściu do bezpieczeństwa było wprowadzenie, w Stanach Zjednoczonych w 1979 roku, testów oceny nowych samochodów – *New Car Assessment Program* (NCAP). Wraz z późniejszymi zmianami stał się on standardowym programem oceny bezpieczeństwa pojazdów wychodzących na rynek [16]. W jego trakcie przeprowadzane są między innymi testy zderzeniowe, pozwalające na ocenę poziomu minimalizacji potencjalnych obrażeń, podczas zderzeń przeprowadzanych w kontrolowanych warunkach i o precyzyjnie określonych parametrach. Jeden z przeprowadzanych testów zderzeniowych przedstawiony jest na rysunku 2.2.

W latach osiemdziesiątych, dzięki rozwojowi technologii komputerowych, stało się możliwe komputerowe projektowanie samochodów za pomocą programów CAD [43], [44]. Postęp w dziedzinie elektroniki sprawił, że coraz bardziej realne zdawało się wprowadzenie zaawansowanych systemów wspomagania kierowcy. Prowadzono badania nad możliwością stworzenia systemu, pozwalającego na wykrycie zamknięcia oczu przez kierowcę za pomocą obrazu z kamer [45]. W tej dekadzie na rynku pojawił się również pierwszy prototyp samochodowej nawigacji satelitarnej [46].



Rysunek 2.2: Test zderzeniowy NCAP 14391 - Ford Ranger XL Supercab [42].

Cyfrowa rewolucja w latach osiemdziesiątych umożliwiła wprowadzenie systemów nawigacji satelitarnej oraz nowych systemów multimedialnych przez wiodących producentów samochodów na początku lat dziewięćdziesiątych. Komunikacja pomiędzy samochodem a kierowcą pozwoliła usprawnić nawigację podczas podróży, ale jednocześnie rozpoczęła szereg procesów mających za zadanie ocenić, jak interakcje z samochodem wpływają na rozproszenie kierowcy. Badania te zaowocowały wprowadzeniem wytycznych do projektowania interfejsów samochodowych [16]. Rozpoczęto również prace nad stworzeniem standardów oraz zaleceń, definiujących interfejsy wbudowane w samochodach [47]–[49]. Pod koniec dziesięciolecia wprowadzono pierwsze aktywne tempomaty, które pozwalały na utrzymywanie bezpiecznej odległości od pojazdu jadącego z przodu [50]. Kolejną przełomową zmianą stały się systemy kontroli trakcji pozwalające na redukcję poślizgu pojazdu. Obecność wyświetlacza w samochodzie pozwoliła na stworzenie pierwszych kamer cofania wbudowanych w samochód [16].

Lata dwutysięczne kontynuowały trend skupiający się na wprowadzeniu coraz bardziej zaawansowanych układów wspomagania kierowcy. Wprowadzono systemy monitorowania martwego pola oraz autonomicznego hamowania w sytuacji, gdy pojazd wykryje niemożliwą do uniknięcia kolizję. [16]. W drugiej dekadzie systemy multimedialne i układy wspomagania kierowcy zaczęły być obecne w samochodach niższej klasy. Upowszechniły się nawigacje samochodowe, komputery pokładowe z możliwością parowania telefonu, co umożliwia prowadzenie rozmów podczas jazdy za pomocą zestawu głośników samochodowych oraz wbudowanych mikrofonów. Czujniki parkowania, kamery cofania oraz aktywne tempomaty są coraz bardziej dostępne, co może wskazywać na tendencje w kierunku uczynienia ich standardowym wyposażeniem samochodowym. Obecny trendem w samochodach najwyższej klasy jest dążenie do umożliwienia autonomicznej jazdy. Ze względu na poziom skomplikowania tego zadania, obecne starania skupione są przede wszystkim na autonomii w ściśle określonych warunkach np. podczas jazdy na autostradzie, stania w korku lub podczas parkowania.

## 2.2 Analiza i wnioski

Analizując przedstawiony rys historyczny, można wskazać następujące etapy rozwoju technologii bezpieczeństwa samochodów osobowych:

1. **Wczesny projekt (1886-1939)** – okres, w którym następowały diametralne zmiany w koncepcji samochodu oraz jego popularyzacja, rozpoczął się wynalezieniem pierwszej „bezkonnej karety”, a zakończył na projekcie samochodu o aerodynamicznym kształcie.
2. **Era pasywnego bezpieczeństwa (1945-1991)** – okres, który rozpoczął się pracami nad wprowadzeniem pierwszych elementów pasywnego bezpieczeństwa, którymi były miękkie obicia deski rozdzielczej, a zakończył się wprowadzeniem pierwszych systemów nawigacji w samochodach.
3. **Era aktywnego bezpieczeństwa oraz zaawansowanych systemów wspomagania kierowcy (1991-obecnie)** – okres zapoczątkowany przez pojawienie się wyświetlaczy umożliwiających nawigację, a który zakończył się wprowadzeniem pierwszych zupełnie autonomicznych pojazdów.

Na przestrzeni ostatniego wieku można zaobserwować, że dużą uwagę producentów i konsumentów cieszą się innowacje wprowadzające:

1. **Zwiększenie bezpieczeństwa** poprzez systemy pasywnego i aktywnego bezpieczeństwa oraz opracowanie standardów definiujących reguły projektowania samochodów oraz ujednolicających kluczowe elementy.
2. **Zwiększenie komfortu** poprzez redukcję czynników powodujących dyskomfort kierowcy i pasażerów, takich jak wibracje samochodu lub niewłaściwa temperatura w kabinie, a także wyręczenie kierowcy w trakcie żmudnych zadań jak jazda w korku lub parkowanie.
3. **Zmniejszenie kosztów** poprzez optymalizację procesu produkcji, redukcja kosztów zaawansowanych systemów, tak aby stawały się dostępne dla szerszej liczby konsumentów, a także redukcja kosztów eksploatacji pojazdu poprzez wprowadzanie bardziej wydajnych silników oraz systemów planowania trasy, które pozwalają na uniknięcie utrudnień na trasie.

Prace badawcze w każdym z przedstawionych kierunków są wartościowe i cieszą się znaczną popularnością. W niniejszej rozprawie podjęto badania, które mogą wspomóc wdrożenie jazdy autonomicznej oraz rozwijanie systemów aktywnego bezpieczeństwa. Ten wybór uzasadniony jest faktem, że jazda autonomiczna jest postępek na wszystkich trzech zdefiniowanych kierunkach rozwoju. W pełni autonomiczna jazda powinna charakteryzować się wyższym poziomem bezpieczeństwa. Zwiększy komfort jazdy, ponieważ kierowca będzie mógł poświęcić swoją uwagę na rzeczy niezwiązane z jazdą. Kabina samochodu będzie mogła zostać przeprojektowana, tak aby zwiększyć komfort kierowcy poprzez poświęcenie widoczności i precyzji sterowania manualnego. Docelowo pełna autonomia pojazdu będzie mogła również umożliwić redukcję kosztów poprzez współdzielenie pojazdu. Jednym z przykładów takiego zastosowania jest przekazanie pojazdu, kiedy nie jest używany do autonomicznej floty „taksówek” – część dochodu

pozwalalaby pokryć koszty eksploatacji takiego samochodu. Innym przykładem są obecne rodziny mieszkające w jednym domu lub w bliskim sąsiedztwie, które często posiadają kilka samochodów pozwalających na dojazd do pracy oraz na zakupy. W przypadku takich rodzin kilka samochodów mogłoby zostać zastąpione jednym, który jest w stanie odwiedzić wszystkich do pracy, szkoły, na zakupy, a także w międzyczasie odebrać zakupy i odwiedzić myjnię automatyczną. Pozwoliłoby to na znaczne zaoszczędzenie czasu oraz kosztów eksploatacji.

Kolejnym argumentem, który wskazuje na atrakcyjność prowadzenia badań związanych z jazdą autonomiczną jest fakt, że są to badania umożliwiające przełom generacyjny. Pełna autonomia pojazdu, może nie tylko zmienić sposób, w jaki z nich korzystamy, ale także znacząco wpłynąć na technologię, gospodarkę oraz społeczeństwo. W pełni autonomiczne autobusy mogłyby zapewnić sieć połączeń w miejscach, które są obecnie wykluczone transportowo z powodu nieopłacalności linii związane z potrzebą zatrudnienia wykwalifikowanego kierowcy, lub brakiem osób chętnych do zajęcia takiego stanowiska, niosąc korzyści gospodarcze (dojazd do nieosiągalnych wcześniej miejsc pracy) oraz społeczne (wyrównanie szans dostępu do edukacji, służby zdrowia i usług). Dodatkowo zwiększone zapotrzebowanie na nowe technologie, umożliwiające jazdę autonomiczną, może stać się motorem napędowym postępu w innych dziedzinach życia.



## Rozdział 3

# Zaawansowane systemy wspomagania kierowcy

Systemy wspomagania kierowcy dzielą się na dwie kategorie, które można rozpoznać po tym, że systemy z jednej grupy są zaprojektowane do zapobiegania wypadkom lub minimalizacji skutków wypadku jeszcze przed jego wystąpieniem, a systemy drugiej kategorii minimalizują efekt wypadków podczas ich wystąpienia. Taka metoda podziału wyodrębnia systemy aktywnego bezpieczeństwa oraz systemy pasywnego bezpieczeństwa [51].

Obecnie produkowane systemy pasywnego bezpieczeństwa charakteryzują się znaczną złożonością oraz wysokimi wymaganiami. Stosowane w przeszłości proste metody minimalizacji obrażeń podczas wypadku, takie jak stosowanie miękkich obić i zagłówek, okazały się niewystarczające i zostały zastąpione układami wspomaganymi elektronicznie. Dzisiejsze systemy są w stanie na podstawie danych z czujników określić nadchodzącą nieuniknioną kolizję lub przewrócenie się samochodu tuż przed tym zdarzeniem. Informacja o nadchodzącej kolizji oraz dane zebrane z systemów monitorowania kabiny służą do określenia optymalnego poziomu napełnienia poduszki powietrznej i przygotowania jej do wystrzelenia. Zebrane informacje pozwalają również na wcześniejsze zaciśnięcie pasów bezpieczeństwa, a także automatyczną zmianę położenia fotela, które zmniejsza ryzyko obrażeń [51]. Pasywne bezpieczeństwo dalej jest rozwijane i w przyszłości można spodziewać się wprowadzenia zewnętrznych poduszek powietrza oraz masek minimalizujących siłę uderzenia w pieszego [52], [53].

Pomimo ciągłego rozwoju systemów pasywnego bezpieczeństwa, największy potencjał wciąż znajduje się w systemach aktywnego bezpieczeństwa. Ich niewątpliwą przewagą jest to, że gdy systemy pasywnego bezpieczeństwa są w stanie jedynie zminimalizować skutki wypadku, to systemy aktywnego bezpieczeństwa mogą mu zupełnie zapobiec. Prewencja w tym przypadku jest jedyną metodą na całkowitą eliminację potencjalnych zniszczeń i uszczerbku na zdrowiu. Systemy aktywnego bezpieczeństwa można podzielić na dwie grupy [51]:

1. prewencyjne – systemy wczesnego ostrzegania kierowcy oraz monitorowania jego stanu m.in. monitorowanie martwego pola widzenia, wykrywanie nieuwagi, zaśnięcia podczas jazdy, a także blokowanie uruchomienia pojazdu w sytuacji, gdy kierowca jest nietrzeźwy lub właściciel pojazdu nie został poprawnie zidentyfikowany (np. za kierownicą usiadło dziecko);

2. dynamicznej kontroli oraz unikania kolizji – systemy odpowiedzialne za utrzymanie pojazdu na oczekiwanej trajektorii (kontrola trakcji, przeciwblokujący układ hamulcowy) oraz za uniknięcie potencjalnego zderzenia poprzez np. autonomiczne hamowanie.

Implementacja systemów aktywnego bezpieczeństwa wymaga założenia, że kierowca jest jednym z układów wykonawczych systemu sterowania pojazdem. Takie podejście przy jednoczesnym określeniu warunków, w których działanie człowieka jest niepewne (np. przy słabym oświetleniu) i opóźnień związanych z czasem reakcji kierowcy, a także monitorowaniu jego stanu pozwala na zwiększenie bezpieczeństwa i skuteczności systemu.

### 3.1 Estymacja stanu pojazdu

Zaawansowany system wspomaganie kierowcy powinien składać się z czujników pozwalających na ocenę stanów pojazdu takich jak [51], [54]:

- pozycja pojazdu;
- wektor prędkości pojazdu (trójwymiarowy);
- przyspieszenie pojazdu;
- prędkość obrotowa bryły pojazdu (trójosiowa);
- kąt skręcenia kierownicy;
- prędkość obrotowa kół;
- stopień zaciśnięcia hamulców;
- bieg pojazdu (informacja o tym, czy włączony jest bieg wsteczny).

Pomiary z czujników zamontowanych w pojeździe, mogą posłużyć jako wejście do estymatora kinematyki pojazdu, za pomocą wielu dostępnych metod opisanych m.in. w [54]. W zależności od typu i liczby stosowanych czujników możliwa jest estymacja zarówno dodatkowych stanów kinematycznych, jak i oszacowanie przyczepności powierzchni [54].

Parametry te pozwalają na określenie, czy samochód porusza się po oczekiwanej przez kierowcę, bezpiecznej trajektorii poprzez model dynamiki pojazdu, jednak ta informacja często okazuje się niewystarczająca do prawidłowej oceny sytuacji.

### 3.2 Obserwacja kabiny i otoczenia

Aby system był zdolny do większej liczby operacji niż utrzymywanie kierowcy na oczekiwanej przez niego trajektorii, konieczne staje się uzyskanie szczegółowej informacji o otoczeniu i innych uczestnikach ruchu. Uzyskanie takich danych można zapewnić przez zastosowanie kamer o wysokiej rozdzielczości i czułości oraz sensorów pozwalających na dokładny pomiar odległości pomiędzy pojazdem a elementami otoczenia.

Sensor	Zalety	Wady	Literatura
Radar	<ul style="list-style-type: none"> <li>• Odporny na zmienne warunki pogodowe</li> <li>• Niezależny od oświetlenia</li> <li>• Pomiar odległości</li> <li>• Pomiar prędkości względnej celów</li> <li>• Duży zasięg</li> </ul>	<ul style="list-style-type: none"> <li>• Trudna klasyfikacja obiektów</li> <li>• Pobór mocy</li> <li>• Możliwość zakłóceń</li> </ul>	[55]–[57]
Lidar	<ul style="list-style-type: none"> <li>• Odporny na zmienne warunki pogodowe</li> <li>• Niezależny od oświetlenia</li> <li>• Pomiar odległości</li> <li>• Wysoka rozdzielczość</li> <li>• Odporność na zakłócenia</li> </ul>	<ul style="list-style-type: none"> <li>• Duży pobór mocy</li> <li>• Wysokie koszty</li> </ul>	[58]–[60]
Kamera	<ul style="list-style-type: none"> <li>• Zbiera dane bez emisji</li> <li>• Wysoka rozdzielczość</li> <li>• Szerokie pole widzenia</li> <li>• Niski koszt</li> <li>• Duża ilość informacji w obrazie</li> </ul>	<ul style="list-style-type: none"> <li>• Duża złożoność obliczeniowa algorytmów wizyjnych</li> <li>• Zależność od warunków pogodowych</li> <li>• Zależność od warunków oświetleniowych</li> </ul>	[61]–[63] [64]–[66]

Tabela 3.1: Wybrane sensory stosowane w ADAS, wraz porównaniem ich wad i zalet [67].

W przemyśle motoryzacyjnym stosowane są kamery, pozwalające na obserwacje w paśmie światła widzialnego oraz w paśmie podczerwieni. Do kategorii czujników odległości można zaliczyć [51]:

1. **czujniki ultradźwiękowe** – stosowane do oceny odległości na bardzo krótkich dystansach, używane głównie do wspomaganie parkowania;
2. **lidary** – urządzenia kierujące ruchomą, laserową wiązkę światła podczerwonego i oceniające odległość do obiektów na podstawie czasu potrzebnego na powrót odbitego światła do sensora;
3. **radary** – urządzenia korzystające z zestawu anten nadawczych i odbiorczych, które są w stanie ocenić kierunek, odległość, odbijalność oraz relatywną prędkość obiektu, od którego została odbita fala elektromagnetyczna.

Lista sensorów które mogą zostać wykorzystane do obserwacji otoczenia wraz z przedstawionymi mocnymi i słabymi stronami przedstawiona jest w tabeli 3.1.

Wykorzystanie odpowiednio zaprojektowanego systemu czujników różnego rodzaju umożliwi uzyskanie bardzo precyzyjnej informacji o otoczeniu i jego uczestnikach, pozwalając na ocenę manewrów wykonywanych przez kierowcę, a także na uzyskanie informacji o miejscach, których nie można obserwować. Są to na przykład popularne kamery cofania, zapewniające pole widzenia bezpośrednio za tylną krawędzią pojazdu lub systemy obserwacji martwego pola widzenia.

System	Elementy wykonawcze				Podstawowe sensory				
	Hamulec	Gaz	Sterowanie	Kierowca	Szybkości	Inercyjne	Dystansu	Obr. kół	Wizyjne
ABS	✓	–	–	–	✓	–	–	✓	–
BAS	✓	–	–	–	–	–	–	✓	–
ACC	–	✓	–	–	✓	–	✓	–	–
TCS	✓	✓	–	–	✓	–	–	–	–
FCW	–	–	–	✓	✓	–	✓	–	–
FCM	–	–	–	–	✓	–	✓	–	–
PA	–	–	✓	✓	–	–	✓	–	✓
FCA	✓	–	✓	–	✓	–	✓	–	–
LKA	–	–	✓	✓	✓	–	✓	–	✓
LCA	–	–	–	✓	–	–	✓	–	✓
ESP	✓	✓	✓	–	✓	✓	–	–	–
RSC	✓	–	–	–	✓	✓	–	–	–

Tabela 3.2: Wybrane systemy ADAS z powiązаныmi elementami wykonawczymi oraz sensorami wymaganymi do działania [51].

Kolejnym typem informacji, który wspomaga działanie systemów aktywnego bezpieczeństwa, są czujniki zamontowane wewnątrz kabiny, pozwalające na jej monitorowanie. Na podstawie kamer wysokiej rozdzielczości, zamontowanych we wnętrzu pojazdu można ocenić, czy kierowca jest skupiony na prowadzeniu pojazdu i z wyprzedzeniem wydać sygnał ostrzegawczy, gdy system rozpozna, że prowadzący samochód zasypia lub został rozproszony rozmową. Informacja ta może zostać wykorzystana nie tylko prewencyjnie, poprzez próbę wybudzenia alarmem lub wymuszenie skupienia na prowadzeniu, ale w skrajnej sytuacji może również posłużyć do bezpiecznego zatrzymania pojazdu na poboczu i uruchomienia świateł awaryjnych. Złożone systemy są w stanie ocenić parametry życiowe kierowcy [68], a postęp w tym kierunku może sprawić, że system będzie w stanie ocenić, kiedy wymaga on natychmiastowej pomocy medycznej i automatycznie wykonać powiadomienie na numer alarmowy.

### 3.3 Systemy ADAS i współpraca z kierowcą

Akcje rekomendowane przez system wspomagania kierowcy muszą zawsze być możliwe do wykonania przez prowadzącego pojazd, jednak działanie wielu systemów aktywnego bezpieczeństwa wymaga by komponenty systemu mogły być sterowane również poprzez sygnał elektroniczny. Obecnie większość komponentów może być sterowana za pomocą komputera pokładowego np. za pomocą technologii „x-by-wire”, która umożliwia sterowanie hamulcami, prędkością oraz biegiem za pomocą elektroniki [67]. Pozwala to na redukcję masy pojazdu poprzez eliminację bezpośrednich połączeń mechanicznych lub hydraulicznych oraz niesie dodatkowe informacje do komponentów wykonawczych. W tabeli 3.2 zawarto listę wybranych systemów aktywnego bezpieczeństwa oraz komponentów, które są wymagane do ich działania.

Powszechnie dostępnymi na rynku systemami aktywnego bezpieczeństwa są między innymi [69]:

- ABS (*Anti-lock Brake System*) - przeciwblokujące układy hamulcowe;

- DSC (*Dynamic Stability Control*) - układy dynamicznej kontroli stabilności;
- układy wspomaganie widoczności.

Dodatkowo coraz większą popularnością cieszą się systemy [69]:

- utrzymywania pasa ruchu;
- automatycznego sterowania;
- unikania kolizji.

Wiele systemów aktywnego bezpieczeństwa wymaga fuzji danych pochodzących z wielu sensorów, by zapewnić większą czułość detekcji obiektów oraz pokrycie pełnego pola widzenia dookoła pojazdu. Takie wykorzystanie czujników może zostać wykorzystane do obserwacji otoczenia, podczas wielu scenariuszy takich jak: skrzyżowania o ograniczonej widoczności, scenariusze z ryzykiem kolizji przedniej oraz tylnej, obserwacja martwego pola widzenia – w trakcie ich zaistnienia umożliwia ostrzeżenie lub wspomaganie kierowcy.

Rozwój systemów wczesnego ostrzeżenia i unikania kolizji skupia się na redukcji fałszywych ostrzeżeń wraz z jednoczesnym zwiększeniem czułości wykrywania obiektów oraz zapewnieniem wysokiej dokładności oceny sytuacji. W przypadku systemów bazujących na informacji, pochodzącej wyłącznie z sensorów zamontowanych w samochodzie, wyzwaniem staje się działanie w warunkach ograniczających pole widzenia, takich jak podczas jazdy na łuku drogi. W warunkach ograniczonej widoczności sensory mogą wygenerować fałszywy alarm np. dla pojazdu nadjeżdżającego z naprzeciwka. Problematiczne mogą stać się również trudne uwarunkowania pogodowe, w których sensory mogą generować pomiary obciążone błędami. W takich wypadkach minimalizacja błędów może zostać zrealizowana za pomocą fuzji danych, jednak nawet przy użyciu wielu sensorów istnieją ograniczenia w postaci ich zasięgu czy barier redukujących pole widzenia [69].

### 3.4 Komunikująca się sieć transportowa

Jednym z badanych rozwiązań, które może zminimalizować ograniczenia percepcji jest bezprzewodowa komunikacja pomiędzy pojazdami (V2V) oraz pomiędzy pojazdem oraz infrastrukturą drogową (V2I). Wraz z rozwojem komunikacji bezprzewodowej możliwa stała się wymiana wiadomości zawierających [69]:

- pozycję;
- prędkość;
- pomiary z sensorów;
- informacje o przeszkodach drogowych;
- ostrzeżenia o trudnych warunkach.

Wymienione metody mogą posłużyć do pozyskania informacji znajdujących się poza zasięgiem widzenia, które są niemożliwe do uzyskania przez lokalne sensory. Mogą one zostać użyte do ostrzeżenia kierowcy o potencjalnej kolizji oraz, w sytuacji krytycznej, wykonanie koniecznego manewru bezpieczeństwa [70].

Inteligentne systemy transportowe (ITS) są w stanie wykorzystywać cyfrową komunikację pomiędzy uczestnikami ruchu drogowego, aby zwiększyć sprawność transportu i jego bezpieczeństwo. Istnieją cztery główne komponenty kooperatywnych ITS [71]:

1. pojazdowy - każdy pojazd musi komunikować się z innymi pojazdami (V2V) i jednostkami przydrożnymi (V2I); w każdym pojeździe wymagane jest zainstalowanie urządzenia komunikacyjnego w celu zarządzania systemem łączności;
2. przydrożny - dowolna jednostka na drodze, która może komunikować się z innymi komponentami (takimi jak pojazdy, inne jednostki przydrożne, osoby lub system centralny);
3. osobisty - są to urządzenia przenośne, takie jak smartfony, które mają możliwość komunikacji z innymi pojazdami, elementami infrastruktury lub innymi smartfonami;
4. centralny - jest to element zarządzający całym systemem komunikacji kooperacyjnej taki jak centrum zarządzania ruchem, które otrzymuje informacje od wszystkich pozostałych komponentów i przekazuje je do pojazdów i jednostek przydrożnych.

Systemy wykorzystujące potencjał połączenia V2V oraz V2I muszą stawić czoła wyzwaniom związanym z przepustowością sieci, cyberbezpieczeństwem, prywatnością, niezawodnością oraz opóźnieniami w transmisji. W celu rozwiązania tych problemów trwają prace nad wprowadzeniem nowych technologii, takich jak DSRC (*Dedicated Short Range Communication*), WAVE (*Wireless Access in Vehicular Environments*), *Vehicular Ad-Hoc Networking* (VANET), a także założono organizacje takie jak C2C-CC (*CAR 2 CAR Communication Consortium*) [72]. Pasma częstotliwości wykorzystywane przez DSRC zostały zaakceptowane do wykorzystania w celu wymiany informacji na krótkich dystansach i umożliwiają one uzyskanie dużej przepustowości danych na potrzeby systemów aktywnego bezpieczeństwa.

*Vehicular Ad Hoc Network* (VANET) to sieć samochodowa, eliminująca wypadki w oparciu o infrastrukturę systemu komunikacyjnego. VANET składa się z dwóch rodzajów sprzętu: jednostek pokładowych, które będą wbudowane w pojazd, oraz jednostek przydrożnych. Definicja VANET przewiduje świadczenie dodatkowych usług za pomocą sieci samochodowej, takich jak rezerwacja miejsca parkingowego, dostęp do internetu i płatność za paliwo [73].

Istnieją dwa wzorce komunikacji: pojazd do infrastruktury (V2I) i pojazd z pojazdem (V2V) [74]. Bezprzewodowe zastosowania związane z bezpieczeństwem pojazdów, zarówno V2V, jak i V2I, wymagają bezpieczeństwa, niezawodnego interfejsu sieci bezprzewodowej w trudnych warunkach pogodowych i małych opóźnień. Wszystkie te wymagania są udostępniane i kontrolowane przez DSRC [73], który jest dwukierunkową usługą komunikacji bezprzewodowej, obsługującą aplikacje aktywnego bezpieczeństwa w środowiskach V2V i V2I. Komisja FCC przydzieliła pasmo 75 [MHz] na częstotliwości 5,9 [GHz] dla DSRC do wykorzystania przez ITS w systemach bezpieczeństwa pojazdów [73] i kontroluje je, nadając wy-

soki priorytet dostępowi do tego widma na potrzeby komunikatów dotyczących bezpieczeństwa. Obecnie DSRC jest uważana za jedyną usługę bezprzewodową, która może zapewnić [73], [75]:

- licencjonowane pasmo;
- szybkie pozyskiwanie sieci, wymagane we wszystkich zastosowaniach związanych z bezpieczeństwem aktywnym;
- małe opóźnienia;
- wysoką niezawodność podczas pracy systemu przy dużej prędkości pojazdu i w ekstremalnych warunkach pogodowych;
- priorytet zastosowań związanych z bezpieczeństwem, w stosunku do zastosowań niezwiązanych z bezpieczeństwem;
- interoperacyjność, która ułatwia wdrożenie w zastosowaniach związanych z bezpieczeństwem aktywnym;
- zabezpieczenia i prywatność w przypadku komunikatów dotyczących bezpieczeństwa.

Celem inteligentnego systemu transportowego (ITS) jest stworzenie wiarygodnego i niezawodnego systemu ostrzegania i unikania kolizji. Nadal jednak istnieją pewne trudności związane z łączem bezprzewodowym oraz informacjami o ruchu pojazdu. Te wyzwania to:

- zatłoczone kanały komunikacji;
- zmienna topologia, zmuszona do szybkiej adaptacji ze względu na dużą mobilność pojazdów;
- potrzeba krótkiego opóźnienia;
- niedokładne informacje GPS o lokalizacji pojazdu;
- zawodne przesyłanie i odbieranie komunikatów o wysokim priorytecie dotyczących bezpieczeństwa.

Systemy zapobiegania kolizjom oparte na czujnikach poprawiły bezpieczeństwo pojazdów, jednakże istnieją pewne ograniczenia podczas korzystania z sensorów w celu uzyskania informacji o otoczeniu pojazdu. Urządzenia pomiarowe nie są w stanie podać dokładnych danych o położeniu innych pojazdów lub obiektów, gdy są one poza zasięgiem sensora. Kolejnym problemem jest ograniczone kątowe pole widzenia czujnika, który w przypadku większości dostępnych sensorów nie jest w stanie zapewnić 360 stopniowego pola widzenia. Technologie ADAS, wykorzystujące komunikację bezprzewodową mają przewagę nad systemami opartymi tylko na czujnikach, ponieważ mogą uzyskać informacje spoza pojazdu. Przykładowe zastosowanie systemów opartych na ITS [69], [71]:

#### 1. Zapobieganie kolizjom czołowym.

W przypadku systemu zapobiegania kolizjom czołowym opartemu na radarach i kamerach zamontowanych w pojeździe, system ostrzega kierowcę i uruchamia hamulce, kiedy wystąpi niebezpieczna

sytuacja na drodze. Niestety inne pojazdy jadące z tyłu nie będą w stanie zareagować, dopóki niebezpieczne obiekty nie znajdą się w zasięgu ich czujników, które mogą mieć ograniczone pole widzenia m.in. przez samochód, który wykonuje manewr bezpieczeństwa. Jeśli możliwe stanie się ostrzeżenie innych uczestników ruchu o niebezpieczeństwie i planowanym manewrze to umożliwi to podjęcie działań, mających na celu uniknięcie ewentualnej kolizji poprzez sąsiednie samochody. Technika ta jest lepsza niż system ostrzegania oparty tylko na czujnikach, który wymaga więcej czasu na wykrycie, przetworzenie i klasyfikację sytuacji niebezpiecznej przed wygenerowaniem ostrzeżenia dla kierowcy.

## 2. Zapobieganie kolizjom na skrzyżowaniach.

Zastosowanie komunikacji bezprzewodowej pomiędzy pojazdami a infrastrukturą pozwala osiągnąć znaczne korzyści. Na skrzyżowaniach dochodzi do wielu wypadków m.in. ze względu na nadużycie sygnalizacji świetlnej oraz widoczność ograniczoną przez budynki, znaki i bariery. Komunikacja bezprzewodowa może zapewnić pojazdom informacje o stanie sygnalizacji świetlnej, umożliwiając wczesną wiedzę o sytuacji na skrzyżowaniu. Ponadto, umożliwiając samochodom wymianę informacji, kierowca może zostać poinformowany o obecności innych, trudno widocznych pojazdów na skrzyżowaniu.

## 3. Ostrzeżenie o niebezpiecznych warunkach drogowych.

W przypadku śliskiej nawierzchni lub niebezpiecznej sytuacji na drodze sieć samochodowa może w odpowiednim czasie przekazać ostrzeżenia do innych samochodów poprzez infrastrukturę. Gdy jeden z pojazdów wykryje zmniejszoną przyczepność nawierzchni może przekazać informację do znajdujących się w zasięgu elementów infrastruktury. Ostrzeżenie o śliskiej nawierzchni będzie wtedy retransmitowane do innych pojazdów znajdujących się w pobliżu, dopóki unormowanie warunków nie będzie potwierdzone przez przejeżdżające samochody.

W literaturze można odnaleźć kilka zaproponowanych technologii zapewniających ochronę przed kolizjami z każdego kierunku i wykorzystujących komunikację pomiędzy samochodami:

### 1. Early Collision Warning Avoidance (ECWA) [76].

ECWA może wygenerować alarm ostrzegający przed kolizją. Wszystkie obliczenia opierają się na wymienionych informacjach o kinematyce pojazdu pochodzących z GPS. Po otrzymaniu tych informacji od innych samochodów, wszystkie pozostałe pojazdy w sieci rozpoczynają obliczenia trajektorii, w celu znalezienia punktu najbliższego zbliżenia. Na podstawie wyników tych obliczeń każdy samochód szacuje prawdopodobieństwo i czas do potencjalnego zderzenia [69].

### 2. Cooperative Collision Warning System (CCCW) [77].

CCW działa na bazie informacji otrzymanych przez GPS i sieć bezprzewodową. Aby uniknąć problemów z niepewnością sygnału GPS, CCCW posiada w każdym pojeździe estymator umożliwiający oszacowanie parametrów pojazdu. Opiera się on na fuzji informacji, pochodzących z czujników pokładowych, takich jak prędkość kół i prędkość kątowna bryły pojazdu, w celu uzyskania dokładniejszych wartości dotyczących pozycji i prędkości pojazdu. Każdy samochód musi być wyposażony

żony w system komunikacji bezprzewodowej, umożliwiającą wymianę tych informacji z innymi pojazdami, tak by mógł aktualizować status wszystkich pojazdów w obszarze zainteresowania w celu wygenerowania mapy otaczających samochodów. Na jej podstawie generowane jest ostrzeżenie o potencjalnym zderzeniu.

### 3. Cooperative Active Safety System (CASS) [78], [79]

CASS wymaga, aby wszystkie pojazdy były wyposażone w odbiornik GPS, nadajnik i odbiornik DSRC, czujniki w pojeździe. Otrzymane dane wejściowe są przetwarzane przez trzy rodzaje estymatorów: Self, Neighbor i Remote, które wyznaczają stan wszystkich pojazdów w bliskim otoczeniu.

Chociaż systemy oparte na ITS nadal wiążą się z wieloma wyzwaniami, przyniosą one ogromne korzyści pojazdom wyposażonym w funkcje ITS, zwiększając bezpieczeństwo i zmniejszając zużycie paliwa [69]. Aby zwiększyć bezpieczeństwo na drogach, konieczne jest połączenie danych z czujników pokładowych i wymiana wiadomości pomiędzy pojazdami w celu uzyskania bardziej pewnej i niezawodnej informacji o otoczeniu [80]. Kluczowym wyzwaniem jest opracowanie zaawansowanego algorytmu fuzji, który uwzględni informacje z obu źródeł i byłby zaawansowany na tyle, by umożliwić jazdę autonomiczną. Jest to skomplikowane zadanie ze względu na łączenie się w sieci bezprzewodowej szybko przemieszczających się pojazdów. Dynamicznie zmieniająca się topologia sieci dodatkowo komplikuje problem asocjacji i synchronizacji pomiarów z czujników pokładowych z danymi innych pojazdów [69], [81], [82].



# Rozdział 4

## Jazda autonomiczna

Pojazdy autonomiczne to pojazdy, które wykorzystują zaawansowane technologie, w tym czujniki, oprogramowanie i systemy sterowania, aby samodzielnie poruszać się po drogach i podejmować decyzje dotyczące przemieszczania się, bez konieczności aktywnego uczestnictwa człowieka. Pozwala to na prowadzenie samochodu bez udziału człowieka, co ma potencjał zwiększenia bezpieczeństwa na drogach oraz poprawienia efektywności transportu [83], [84].

### 4.1 Poziomy autonomiczności

W miarę rozwoju technologii zwiększa się poziom autonomii pojazdów. W ostatnich latach na rynku pojawiają się systemy, które są zdolne do przejęcia kontroli nad pojazdem w ściśle określonych warunkach, takich jak powolne poruszanie się w korku lub jazda z utrzymaniem bezpiecznej odległości za poprzedzającymi pojazdami na autostradzie. Do osiągnięcia pełnej autonomii przez samochody należy rozwiązać wiele problemów i wydaje się, że do dostępności w pełni autonomicznych samochodów na rynku potrzeba jeszcze znaczącego czasu. Nic nie stoi jednak na przeszkodzie, aby częściowo autonomiczne pojazdy wspierały kierowców przy zastosowaniu odpowiednich środków ostrożności i jasnej informacji o stopniu automatyzacji samochodu.

Jedną z pierwszych metod klasyfikacji poziomów autonomiczności została opracowana w 1987 roku przez Sheridana i Verplanka, a następnie została zmodyfikowana przez Parasuramana i in. w roku 2000 [85], [86]. Zdefiniowane zostało dziesięć poziomów automatyzacji w oparciu o rolę człowieka i pojazdu w procesie prowadzenia:

- **Poziom 1** – brak automatyzacji, wszystkie decyzje oraz działania są podejmowane przez człowieka;
- **Poziom 2** – system sugeruje zestaw wszystkich możliwych do wykonania akcji;
- **Poziom 3** – system sugeruje kilka najkorzystniejszych do wykonania działań;
- **Poziom 4** – system proponuje jedno działanie do wykonania;
- **Poziom 5** – system może podejmować decyzje po uzyskaniu zgody operatora;

- **Poziom 6** – system umożliwia kierowcy reakcję w określonym czasie przed automatycznym działaniem;
- **Poziom 7** – system informuje człowieka o tym działaniu jakie podejmuje;
- **Poziom 8** – system informuje człowieka jedynie na żądanie;
- **Poziom 9** – system decyduje, czy osoba nadzorująca powinna być powiadomiona po akcji automatycznej;
- **Poziom 10** – system działa w pełni autonomicznie, ignorując człowieka.

Wraz z postępem badań nad wdrożeniem autonomii stało się jasne, że podział ten pomimo dużej granulacji, posiada znaczną wadę, ponieważ zdaje się implikować, że poziom autonomii będzie taki sam we wszystkich uwarunkowaniach, co wydaje się niemożliwe przy obecnym zaawansowaniu technologii autonomicznej. Obecnie produkowane pojazdy są w stanie działać bez ingerencji człowieka, ale jedynie w ściśle określonych warunkach, które mogą ulec zmianie. Dodatkowo poziomy 2 i 3 w tej klasyfikacji wydają się niepraktycznymi rozwiązaniami, które nigdy nie wejdą do produkcji.

Warto zaznaczyć, że autonomia nie jest ekskluzywna dla przemysłu samochodowego. Prace nad wdrożeniem systemów autonomicznych trwają między innymi w rolnictwie, transporcie kolejowym, tramwajach oraz metrze, a ich poziom autonomii ze względu na bardziej przewidywalne środowisko, wydaje się być większy niż w przypadku samochodów. W dziedzinie inżynierii lotniczej stopnie automatyzacji są bardziej ugruntowane ze względu na wprowadzenie tzw. autopilotów. Działania autonomii w lotnictwie są zdefiniowane bardziej szczegółowo i składają się z sześciu poziomów, znanych jako struktura autoryzacji i kontroli zadań pilota (PACT - *Pilot Authorisation and Control of Tasks*) [87]. System automatyzacji PACT jest opisany stopniami od 0 do 5. Poziom 0 oznacza brak autonomii komputera, a poziom 5 oznacza, że systemy mogą działać w pełni automatycznie, ale nadal mogą być przerwane przez człowieka [87]. Przedstawiony w [88] szczegółowy podział zadań dla pilota oraz systemu komputerowego, który różni się w zależności od poziomu autonomii, uzmysławia stopień skomplikowania systemów autonomicznych, nawet w przypadku przewidywalnego i dokładnie monitorowanego środowiska jakim jest przestrzeń powietrzna.

Amerykańska Krajowa Administracja Bezpieczeństwa Ruchu Drogowego (NHTSA) zdefiniowała pięć poziomów automatyzacji [89], a w ostatnich latach zaadaptowała szeroko stosowaną definicję AD od *Society of Automotive Engineers* (SAE) [90], która jest systematycznie aktualizowana [91]. SAE zdefiniowało sześć poziomów automatyzacji pojazdów od 0 (brak automatyzacji) do 5 (pełna automatyzacja jazdy), w zależności od roli czynnika ludzkiego w systemie automatyki. SAE definiuje sześć poziomów automatyzacji jazdy, które są szeroko akceptowane przez producentów samochodów, organy regulacyjne i decydentów [90]–[93]. Te poziomy automatyzacji są podzielone ze względu na rolę kierowcy i systemu automatyki w procesie sterowania różnymi zadaniami prowadzenia pojazdu, w tym:

- sterowanie i kontrolę prędkości (sterowanie gazem i hamulcem);
- monitorowanie otoczenia;
- konieczność przejścia sterowania w razie problemów z jazdą;

- zdolności systemu w zakresie różnych trybów jazdy autonomicznej.

Sześć poziomów automatyzacji jazdy zdefiniowanych przez *Society of Automotive Engineers* (SAE) prezentuje się w sposób następujący [90], [91], [94]:

- **Poziom 0 – Brak automatyzacji**

Człowiek wykonuje wszystkie zadania związane z prowadzeniem pojazdu.

- **Poziom 1 – Wspomaganie kierowcy**

Człowiek steruje pojazdem, jednak systemy automatyzacji wspomagają proces prowadzenia pojazdu.

- **Poziom 2 – Częściowa automatyzacja jazdy**

Pojazd wykorzystuje zintegrowane funkcje automatyzacji, ale operator nadal monitoruje otoczenie i utrzymuje kontrolę nad procesem jazdy.

- **Poziom 3 – Warunkowa automatyzacja jazdy**

Osoba kontrolująca pojazd musi być gotowa przejąć prowadzenie w dowolnym momencie, gdy taka potrzeba się pojawi.

- **Poziom 4 – Wysoka automatyzacja jazdy**

System automatyzacji może prowadzić pojazd automatycznie w określonych warunkach, a kierowca jest w stanie obsługiwać pojazd.

- **Poziom 5 – Pełna automatyzacja jazdy**

System automatyzacji jest zdolny do prowadzenia pojazdu automatycznie we wszystkich warunkach, a kierowca ma zdolność do nadzorowania pojazdu.

Według tej klasyfikacji większość obecnie opracowywanych systemów przypisać można do poziomu 3, który opisuje ograniczoną automatyzację jazdy autonomicznej, w której w niektórych przypadkach kierowcy mogą przejąć kontrolę [95]. Warto zaznaczyć, że obecna norma SAE szczegółowo opisuje klasyfikację i dopuszcza sklasyfikowanie automatyzacji pojazdu – w zależności od sytuacji drogowej. Możliwe jest więc istnienie systemu, który na autostradzie posiada poziom 4 autonomii, ale tylko 2 podczas jazdy po mieście [91].


## 4.2 Architektura systemów AD

Pojazdy autonomiczne mają zdolność postrzegania otaczającego środowiska i poruszania się samodzielnie, bez potrzeby interwencji człowieka. Aby umożliwić autonomiczną jazdę, pojazd musi być wyposażony w elektroniczne systemy sterowania oraz czujniki do wykrywania otoczenia. Ponadto, niezbędne są złożone i niezależne algorytmy jazdy, wymienione m.in. w [96]. Typowa architektura systemu AD składa się z czterech elementów:

1. **Warstwa percepcji** – polegająca na wykrywaniu otaczającego środowiska za pomocą różnorodnych technik i urządzeń, takich jak radary, lidary i rozpoznawanie obrazu (*computer vision*);

2. **Warstwa decyzyjna** – określająca zachowania i ruch pojazdu, w oparciu o informacje z percepcji i lokalizacji ustalonej przy wykorzystaniu GPS;
3. **Warstwa wykonawcza** – realizująca zaplanowane akcje poprzez sterowanie skrzętem kół oraz kontrolę nad prędkością samochodu;
4. **Warstwa nadzorcza** – nadzorująca układ napędowy, zarządzanie awariami oraz rejestrująca ewentualne błędy i usterki systemu [97].

Działanie poszczególnych warstw zademonstrowane jest na rysunku 4.1. Przedstawia on scenariusz, na którym inny uczestnik ruchu wykonuje manewr prowadzący do kolizji. Warstwa percepcji, która stale monitorowała otoczenie i wyestymowała najpewniejszą trajektorię celu, zgłasza ryzyko kolizji. Warstwa decyzyjna generuje hipotezy potencjalnych manewrów, które zminimalizują ryzyko kolizji lub potencjalne szkody. Najbezpieczniejsza trajektoria pojazdu zostaje przekazana do warstwy wykonawczej, która wykonuje manewr. Warstwa nadzorcza stale monitoruje stan całego pojazdu oraz zgodność ruchu z zadaniem manewrem.



Rysunek 4.1: Przykład działania warstw architektury systemu AD. Cel (żółty) wykonuje manewr niebezpieczny (trajektoria szara), system ocenia hipotezy trajektorii i po odrzuceniu prowadzących do kolizji (czerwone), wybiera najbezpieczniejszą (zieloną), która zostanie wykonana.

#### 4.2.1 Warstwa percepcji

Pod koniec XX wieku powszechnie wykorzystywano czujniki proprioceptywne, takie jak czujniki ciśnienia kół, inercyjne czujniki położenia oraz odometrię, w celu poprawy stabilności dynamicznej pojazdów i wdrażania funkcji TCS, ABS, ESP, RSC, DSC [98]. W pierwszej dekadzie XXI wieku skupiano się na czujnikach eksteroreceptywnych, takich jak sensory ultradźwiękowe, radary, LIDAR, kamery, czujniki podczerwieni oraz globalne systemy nawigacji satelitarnej, w celu zwiększenia komfortu podczas jazdy oraz wdrożenia systemów ostrzegania kierowcy [98].

W ostatniej dekadzie zaawansowane sieci czujników w pojazdach i infrastrukturze drogowej znalazły zastosowanie w ITS, umożliwiając zautomatyzowaną i kooperatywną jazdę [99]. Rozwinięto zaawansowane

funkcje ADAS, w tym FCA, FCM oraz jazdę autonomiczną niskiego poziomu, ułatwiając prowadzenie pojazdu w żmudnych warunkach. W miarę zwiększania stopnia automatyzacji pojazdu, dane percepcyjne mogą być również generowane poprzez komunikację między pojazdem a infrastrukturą drogową [100], [101], innymi pojazdami [102], [103], Internetem i chmurą [104]. Szczegóły dotyczące różnych technologii detekcji można znaleźć m.in. w [102].

Informacje o otaczającym środowisku są zbierane przy użyciu różnych rodzajów urządzeń pomiarowych. Systemy radarowe wykorzystują fale radiowe do pomiaru odległości, kąta i prędkości względnej obiektów. Systemy lidarowe generują trójwymiarową chmurę punktów otoczenia, poprzez wysyłanie impulsu laserowego i ocenę odległości na podstawie czasu jego powrotu. Kamery przy użyciu algorytmów wizyjnych oraz metod uczenia maszynowego mogą posłużyć do klasyfikacji obiektów m.in. rozpoznania znaków drogowych [105]–[107]. Informacje przesyłane są do warstwy decyzyjnej, po połączeniu danych z sensorów algorytmem fuzji [96].

Lokalizacja pojazdu jest mierzona dzięki technologii GPS, wspomaganą przez dane z czujników inercyjnych pojazdu oraz informacje o otoczeniu i cyfrowe mapy. To pozwala na uwzględnienie błędów, które mogą pojawić się w przypadku zakłóceń sygnału GPS [96].

#### 4.2.2 Warstwa decyzyjna

Warstwa percepcji odpowiada za gromadzenie danych z wielu urządzeń czujnikowych, które pozwalają na analizę warunków otoczenia i podejmowanie decyzji w czasie rzeczywistym [83], [108]. Rozwój pojazdów autonomicznych w dużej mierze opiera się na złożoności, niezawodności, użyteczności i dojrzałości technologii detekcji [108].

Warstwa decyzyjna przetwarza wszystkie dane z warstwy percepcji, podejmuje decyzje i generuje informacje niezbędne dla warstwy działania [83], [109]. Świadomość sytuacyjna pełni rolę istotnego wkładu w systemie decyzyjnym, służąc do planowania zarówno krótko-, jak i długoterminowego. Planowanie krótkoterminowe obejmuje generowanie trajektorii, unikanie przeszkód, zarządzanie zdarzeniami oraz manewrami. Natomiast planowanie długoterminowe dotyczy bardziej złożonych aspektów, takich jak planowanie optymalnych tras z uwzględnieniem wymaganych postojów [100], [110]–[112].

Algorytmy planowania operują na trzech etapach: globalnym planowaniu trasy (znalezienie najszybszej i najbezpieczniejszej drogi z punktu początkowego do docelowego), wnioskowaniu behawioralnym (ocena sytuacji drogowej i określenie zachowania pojazdu autonomicznego na podstawie trasy i informacji sensorycznych) oraz lokalnym planowaniu ruchu (unikanie kolizji z przeszkodami) [107]. Warto zaznaczyć, że oprogramowanie autopilota w pojazdach autonomicznych musi uwzględniać aspekty etyczne, aby odwzorować proces podejmowania decyzji przez człowieka [96], [113].

#### 4.2.3 Warstwa wykonawcza

Kluczową technologią umożliwiającą sterowanie pojazdem autonomicznym jest *drive-by-wire*. Oznacza to zastąpienie układów mechanicznych lub hydraulicznych, takich jak przyspieszanie (*throttle-by-wire*), hamowanie (*brake-by-wire*) oraz sterowanie (*steer-by-wire*), układami elektronicznymi [114]. W celu realizacji wszystkich funkcji jazdy w pojazdach autonomicznych dodaje się dodatkowe moduły sterujące (ECU).

Chociaż technologia *drive-by-wire* pojawia się również w pojazdach z silnikiem spalinowym, jest ona szczególnie istotna w przypadku pojazdów elektrycznych. W pojazdach elektrycznych technologia *brake-by-wire* umożliwia odzyskiwanie energii podczas hamowania poprzez oddzielenie pedału hamulca od samego układu hamulcowego [115].

Drive-by-wire to technologia krytyczna dla bezpieczeństwa, dlatego musi zapewnić odporność na awarię m.in. poprzez redundancję w systemie sterowania. W przypadku kluczowych systemów *drive-by-wire*, system kontroli musi zapewnić, że ich niepoprawne funkcjonowanie nie stanie się zagrożeniem dla życia ludzi ani środowiska, oraz że utrata pojedynczego elementu nie spowoduje awarii całego systemu napędowego [114].

### 4.3 Błędy systemów AD

Wraz z postępującym stosowaniem coraz bardziej autonomicznych systemów, mogą występować różnego rodzaju problematyczne zdarzenia. Jeżeli błędy systemu nie zostaną odpowiednio wykryte i naprawione, mogą prowadzić do poważnych problemów związanych z bezpieczeństwem. Systematyczna analiza różnych typów nieprawidłowości lub incydentów związanych z pojazdami autonomicznymi pomoże zrozumieć aktualny stan bezpieczeństwa tych pojazdów. Ponieważ technologia pojazdów autonomicznych nadal znajduje się we wczesnym etapie komercjalizacji i jest daleka od osiągnięcia pełnej autonomii w prowadzeniu, konieczne jest przeprowadzenie większej liczby testów drogowych.

Kwestie bezpieczeństwa oraz incydenty związane z pojazdami autonomicznymi są ściśle uzależnione od pomyłek popełnionych przez te pojazdy na różnych poziomach automatyzacji. Tego rodzaju uchybienia można sklasyfikować zgodnie z wcześniej wspomnianą architekturą.

#### 4.3.1 Błąd percepcji

Wszelkie problemy w postrzeganiu statusu, lokalizacji i ruchu innych uczestników ruchu, sygnałów drogowych i innych zagrożeń mogą wpłynąć na bezpieczeństwo pojazdów autonomicznych. Błędy percepcji mogą wynikać z trzech głównych źródeł [95]:

- sprzętu - spowodowanych uszkodzeniem lub degradacją czujników lub brakiem kalibracji;
- oprogramowania - spowodowanych niepoprawną implementacją algorytmów;
- komunikacji - spowodowanych przez złe rozpoznanie intencji innych uczestników ruchu.

Problemy sprzętu i oprogramowania mogą dostarczyć do warstwy decyzyjnej niepoprawny obraz otoczenia, dezorientując ją i powodując niebezpieczne zachowania podczas jazdy. W związku z tym kluczowe jest wprowadzenie niezawodnych i odpornych na błędy czujników [100].

Użytkownicy dróg, tak jak kierowcy, piesi, rowerzyści i pracownicy budowlani, komunikują się ze sobą, aby koordynować ruch i zapewnić bezpieczeństwo na drodze. To fundamentalne wymaganie stawiane jest także pojazdom autonomicznym [116]. Metody komunikacji obejmują gesty, mimikę oraz interakcje między pojazdami. Na interpretację tych komunikatów mogą wpływać różne czynniki, w tym kultura, kontekst

i doświadczenie. Wyzwania związane ze zrozumieniem tych aspektów są kluczowe dla technologii pojazdów autonomicznych [117]. Błędy w komunikacji staną się istotne, gdy pojazdy autonomiczne osiągną pełną automatyzację. Problemy te mogą wynikać z problemów w komunikacji między pojazdem a infrastrukturą drogową [100], innymi uczestnikami ruchu [102] oraz Internetem [104]. Komunikacja interpersonalna stanowi kluczowy element nowoczesnego systemu transportowego [117].

### 4.3.2 Błąd decyzji

Błędy decyzyjne wynikają głównie z czynników systemowych lub ludzkich. W przypadku niskich poziomów autonomii efektywny system AD ostrzega kierowcę tylko wtedy, gdy jest to absolutnie konieczne, minimalizując jednocześnie liczbę fałszywych alarmów, przy zachowaniu akceptowalnego poziomu bezpieczeństwa [118], [119].

Niemniej jednak, w przypadku, gdy algorytm nie jest w stanie skutecznie i efektywnie wykryć wszystkich zagrożeń, bezpieczeństwo pojazdu AD może zostać narażone. Niestety obecne systemy AD nadal nie są całkowicie niezawodne. Z tego powodu kierowca musi być gotowy do przejęcia sterowania, nadzoru i monitorowania zadań związanych z prowadzeniem pojazdu, jeśli AD zawiedzie lub będzie działał poniżej oczekiwań [120], [121]. Warto podkreślić, że człowiek może potrzebować kilku sekund na reakcję lub przejęcie sterowania od chwili uzyskania komunikatu od systemu. [120], [122], [123].

Malejąca rola kierowcy w kontekście pojazdów autonomicznych może prowadzić do problemów z koncentracją, spadku świadomości sytuacyjnej oraz pogorszenia umiejętności manualnych [124]. Dlatego projektując samochody autonomiczne, należy wziąć pod uwagę, w jaki sposób można bezpiecznie i skutecznie zaangażować człowieka ponownie w proces prowadzenia w przypadku awarii systemów autonomicznych [95].

### 4.3.3 Błąd akcji

Po otrzymaniu polecenia z warstwy decyzyjnej, kontroler akcji musi sterować kierownicą, gazem i hamulcem, umożliwiając zmianę kierunku, przyspieszenie lub zwolnienie [125], [126]. Układy wykonawcze powinny dostarczać również sprzężenia zwrotnego, które zostanie wykorzystane do generowania nowych poleceń. Podobnie jak w przypadku tradycyjnych samochodów, błędy związane z prowadzeniem pojazdu wpływają na bezpieczeństwo. Niemniej jednak kierowca jest w stanie rozpoznać problem i w krótkim czasie zatrzymać pojazd.

Prawidłowa reakcja na rzadkie, ale poważne awarie głównych podzespołów pojazdu, stanowi wyzwanie dla pojazdów autonomicznych. Z tego powodu istotne jest analizowanie wypadków tradycyjnych samochodów, aby zapewnić odpowiednie dane do uczenia algorytmów AD [127].

## 4.4 Potencjał jazdy autonomicznej

Właściwie rozwinięta i wdrożona technologia pojazdów autonomicznych przyniesie różne korzyści m.in. [95], [128]–[131]:

### 1. **Bezpieczeństwo**

Pojazdy autonomiczne są w stanie szybko określić bezpieczne manewry m.in. dzięki uczeniu ich na wirtualnych scenariuszach, co pozwala na zapewnienie, że w sytuacjach niebezpiecznych wykonają najbezpieczniejszy ruch [120], [122], [123], [132]. Komunikacja bezprzewodowa pomiędzy pojazdami autonomicznymi dodatkowo poprawi bezpieczeństwo, ponieważ każdy z pojazdów będzie wiedział o planowanych trajektoriach pojazdów w swoim otoczeniu.

### 2. **Ekonomia jazdy**

Większa liczba pojazdów autonomicznych sprawi, że ruch na drodze stanie się przewidywalny i płynny. Pojazdy poruszające się ze stałą prędkością zmniejszą zużycie paliwa, zmniejszając koszty oraz wpływ na środowisko naturalne [133].

### 3. **Zwiększone wykorzystanie pojazdów**

W przypadku w pełni autonomicznych pojazdów kierowca nie jest koniecznym elementem sterowania. Dzięki temu z samochodu będą mogli korzystać m.in.:

- osoby bez prawa jazdy;
- osoby o ograniczonej mobilności kończyn, np. ze złamaną ręką;
- osoby w złej kondycji np. przemęczone, chore, pod wpływem silnych emocji;
- osoby pod wpływem środków psychoaktywnych (lekarstw lub używek);

co znacznie zwiększy standard życia.

### 4. **Redukcja stresu**

Kierowcy będą mogli poświęcić czas jazdy na odpoczynek lub rozwój osobisty. To z kolei przyczyni się do zwiększenia produktywności w pracy oraz pozytywnie wpłynie na sferę rozrywki i nauki.

## 4.5 Wyzwania jazdy autonomicznej

Aby umożliwić rozwój pojazdów autonomicznych oraz ich powszechną akceptację w społeczeństwie, należy rozwiązać pewne kluczowe wyzwania [95]:

### 1. **Minimalizacja błędów percepcji**

Należy zapewnić dokładne wykrywanie, lokalizowanie i klasyfikowanie obiektów w otoczeniu oraz właściwe rozpoznanie ich intencji na drodze. W tym celu konieczne jest zapewnienie wysokiej dokładności pomiarów oraz wdrożenie nowych systemów do pojazdów autonomicznych, takich jak rozpoznanie postawy, gestyki i mowy uczestników ruchu.

### 2. **Minimalizacja błędów decyzyjnych**

Konieczne jest opracowanie niezawodnego, wiarygodnego i wydajnego systemu podejmowania decyzji, umożliwiającego precyzyjne i szybkie reagowanie na zmieniające się warunki środowiskowe. Osiągnięcie tego celu wymaga rygorystycznych testów sprzętu i oprogramowania. Systemy AD muszą zapewnić właściwe działanie i np. priorytetowo traktować bezpieczeństwo pieszych w przypadku nagłych usterek systemu lub awarii mechanicznych.

### 3. Minimalizacja błędów działania

Bezpieczeństwo AD wymaga płynnej komunikacji elementów wykonawczych z systemami decyzyjnymi oraz precyzyjnego wykonywania poleceń od systemów zautomatyzowanych, z wysokim stopniem niezawodności i stabilności.

### 4. Bezpieczeństwo cybernetyczne

W miarę postępu technologicznego, pojazdy autonomiczne będą wchodzić w bezprzewodową komunikację z infrastrukturą drogową, satelitami i innymi pojazdami. Zapewnienie cyberbezpieczeństwa staje się kluczową kwestią dla technologii AD [134].

### 5. Współdziałanie z tradycyjnym systemem transportowym

Pojazdy autonomiczne muszą współistnieć na drogach z tradycyjnymi samochodami i pieszymi, co skomplikuje interakcję między systemem AD a innymi uczestnikami ruchu [135]. Rozróżnienie rodzajów pojazdów, z którymi wchodzi w interakcję inni użytkownicy dróg, jest trudne.

### 6. Akceptacja klientów

Komercjalizacja technologii AD napotyka przeszkody, w tym kwestie bezpieczeństwa [136], koszty [137], [138] oraz interes publiczny [139]–[144]. W szczególności bezpieczeństwo ma istotny wpływ na społeczne nastawienie do powstającej technologii AD.

### 7. Regulacje prawne

Samochody autonomiczne mogą poruszać się tylko w regionach, w których pozwala na to obowiązujące w nich prawo. Przed wjazdem na terytorium, w którym użytkowanie pojazdów autonomicznych jest nielegalne, system powinien poinformować kierowcę o konieczności przejęcia kontroli. Zupełnie autonomiczny pojazd powinien zwalniać z jakiegokolwiek odpowiedzialności jego pasażerów, ale zanim zostanie to unormowane w przepisach, producenci mogą stworzyć regulaminy oraz umowy z warunkami ogólnymi użytkowania, które przeniosą odpowiedzialność na pasażera.



## Rozdział 5

# Multisensoryczna fuzja danych w zastosowaniach samochodowych

Systemy percepcji w przemyśle samochodowym w dużej mierze opierają się na metodach fuzji danych pochodzących z wielu sensorów, które często są różnego typu. Proces ten polega na przekazywaniu informacji pochodzących z różnych źródeł do jednostki obliczeniowej i łączeniu ich w spójną całość. Zastosowanie takiej metody pozwala na uzyskanie obrazu otoczenia, który byłby niemożliwy do uzyskania w wyniku pomiarów z pojedynczego czujnika. Przykładowa architektura takiego systemu przedstawiona jest na rysunku 5.1.



Rysunek 5.1: Podstawowa zasada działania fuzji danych. Sensory dostarczają dane, które są przetwarzane i łączone w zunifikowane wyjście. Inspirowane [145].

Technologia fuzji jest badana od wielu dekad. Wczesna aplikacja skupia się na zastosowaniach w przemyśle wojskowym, korzyści wynikające z jej zastosowania zostały szybko dostrzeżone i wdrażane w innych dziedzinach [146]. Obecnie trudno wskazać branżę, w której fuzja danych nie jest stosowana, a algorytmy fuzji są obecne w otoczeniu większości populacji np. w telefonach komórkowych, w których fuzja systemu GPS i akcelerometru umożliwia dokładną nawigację.

Fuzja danych, pomimo nazwy wskazującej na ugruntowanie ściśle technologiczne jest procesem zainspirowanym przez naturę i powszechnie stosowanym przez ludzi oraz zwierzęta. Wykształcenie mecha-

nizmów fuzji danych wydaje się jednym z kluczowych elementów, które znacząco podnoszą zdolność do przetrwania gatunku [146]. Przykładami biologicznego zastosowania tego mechanizmu są między innymi:

- badanie jadalności substancji za pomocą informacji pochodzących ze zmysłów wzroku, dotyku, zapachu oraz smaku [146]. W przypadku zwierząt stadnych o zdolności do komunikacji oraz ludzi, również na podstawie informacji przekazanej od innych jednostek;
- wykrywanie zagrożeń na podstawie wzroku, słuchu i węchu, które pozwala na znacznie wcześniejszą reakcję.


Powyższe zastosowania wskazują na korzyści płynące z połączenia różnych typów czynników, ale zarówno w przypadku organizmów żywych, jak i systemów elektronicznych korzystne może być łączenie wielu sensorów tego samego rodzaju. Przykładami takich zastosowań są:

- uszy, zwykle występują w parze, co pozwala na ocenę kierunku nadchodzącego dźwięku, których technologicznym odpowiednikiem są sonary, zbudowane z zestawu mikrofonów, umożliwiających ocenę kierunku na podstawie przesunięcia fazowego pomiędzy nadchodzącymi sygnałami;
- oczy, które w zależności od rodzaju zwierzęcia pozwalają na rozszerzenie pola widzenia lub, jak w przypadku ludzi, na poprawę postrzegania głębi, co w przypadku rozwiązań elektronicznych znalazło zastosowanie w systemach „widoku z lotu ptaka” oraz kamerach stereowizyjnych.

Niewątpliwą zaletą systemów opartych na fuzji danych jest również redundancja pomiarów pozwalająca na działanie systemu z częściową lub pełną sprawnością, nawet w przypadku uszkodzenia pojedynczego sensora lub jego działania w środowisku wprowadzającym zakłócenia pomiarowe [146]. Powielenie informacji pomiarowej niestety znacząco podnosi koszty oraz zwiększa złożoność obliczeniową algorytmów fuzji, stopień redundancji jest zwykle ograniczany w większości zastosowań komercyjnych.

Połączenie zupełnie różnych typów sensorów, tak jak w podanym przykładzie oceny jadalności substancji, nie jest jedyną metodą fuzji. Bardzo ciekawe efekty można uzyskać poprzez pomiar podobnych parametrów za pomocą różnych urządzeń. Jednym z przykładów takiego zastosowania jest radar o niskiej rozdzielczości kątowej i kamera termowizyjna. Oba te urządzenia mierzą szeroko rozumianą pozycję celu, w podanym przez Halla w [146] przykładzie kamera termowizyjna pozwala na znacznie dokładniejszą ocenę pozycji kątowej obiektu niż radar, natomiast ocena odległości za jej pomocą była praktycznie niemożliwa.

W przytoczonym przez Halla przykładzie ocena odległości była nieosiągalna, ponieważ nie pozwalała na to obecna w tamtych czasach technologia. Obecnie, powszechnie stosowane sieci neuronowe pozwalają na estymację odległości na bazie obrazu z pewną niepewnością, która jest jednak znacznie większa niż precyzja radaru [147]. Z tego względu można wyciągnąć podobne wnioski, że połączenie informacji o położeniu kątowym oraz odległości za pomocą algorytmu fuzji znacząco poprawi informacje o położeniu obiektu. W tak oczywistym przypadku nawet zastosowanie średniej ważonej zaprezentowanych pomiarów może okazać się metodą istotnie zwiększającą jakość pomiarów. Ilustracja opisanego przypadku znajduje się na rysunku 5.2.



Rysunek 5.2: Przykład intersekcji obszarów niepewności. Czerwony i niebieski prostopadłościan symbolizują przedziały niepewności pomiaru dwóch urządzeń. Zielony obszar jest ich częścią wspólną. Inspirowane [146].

Wskazany przykład pozwala wysunąć wniosek, że implementacja systemu bazującego na fuzji sensorów wymaga od jej architekta znajomości mocnych i słabych stron stosowanych urządzeń pomiarowych. Największe korzyści można osiągnąć stosując bardzo dokładną wiedzę na temat wyników, pozwalającą ocenić ich niepewności w różnych warunkach i używając szerokiej wiedzy w różnych dziedzinach, o których wspominał Hall, takich jak teoria i przetwarzanie sygnałów, estymacja statystyczna, sztuczna inteligencja oraz metody numeryczne [146]. Wiedza z tych dziedzin staje się konieczna w przypadku implementacji bardziej złożonych algorytmów śledzących parametry obiektu w czasie, filtrujących sygnały wejściowe, szacujących niepewność informacji wejściowej i wyjściowej itd.. Co również istotne na etapie projektowania systemów należy uwzględnić przypadki szczególne, które mogą zostać łatwo pominięte. Jednym z takich scenariuszy może być nieoświetlony tunel. Działanie w takich warunkach algorytmu jazdy autonomicznej wymaga dobrania zestawu czujników, które pozwolą na funkcjonowanie w takich warunkach. Może to być problematyczny scenariusz, ponieważ działanie radarów jest ograniczone w tunelach ze względu na istnienie wielokrotnych odbić fali elektromagnetycznej od ścian. Podobnie w przypadku sygnału GPS, który zniknie oraz kamery, która może zostać oślepiona podczas dojazdu do końca tunelu. Jak wspominał Hall, podczas projektowania takich systemów należy odpowiedzieć na pytania [146]:

1. Jakie algorytmy i metody są właściwe dla wybranego zastosowania?
2. Na jakim etapie powinna nastąpić fuzja danych?
3. Jak należy przetworzyć pomiary sensorów, tak aby uzyskać maksymalną ilość informacji?
4. Jaka jest rzeczywista dokładność uzyskiwana w wyniku fuzji danych?
5. Jak można w sposób dynamiczny optymalizować proces fuzji?
6. W jaki sposób środowisko pomiarowe wpływa na proces?
7. W jakich warunkach wieloczynnikowa fuzja danych poprawia działanie systemu?

Ze względu na rosnącą popularność metod opartych na uczeniu maszynowym zasadne stają się również pytania:

1. Czy w rozważanym systemie fuzja danych za pomocą głębokich sieci neuronowych może przynieść wymierne korzyści?
2. Czy moc obliczeniowa i pamięć w rozważanym systemie pozwalają na implementację sieci neuronowych?
3. Czy na etapie projektu będzie możliwe zebranie wystarczającej ilości danych do wytrenowania sieci tak, aby spełniała wymagania projektowe?
4. Czy możliwe jest zebranie informacji referencyjnej pozwalającej na użycie jej do trenowania?

W tym rozdziale omówione zostaną architektury fuzji danych, przekrój stosowanych algorytmów, używane w przemyśle samochodowym czujniki pozwalające na fuzję danych, a także, co ważne w kontekście opisywanej pracy doktorskiej, problemy systemów fuzji i przykłady jej zastosowań.

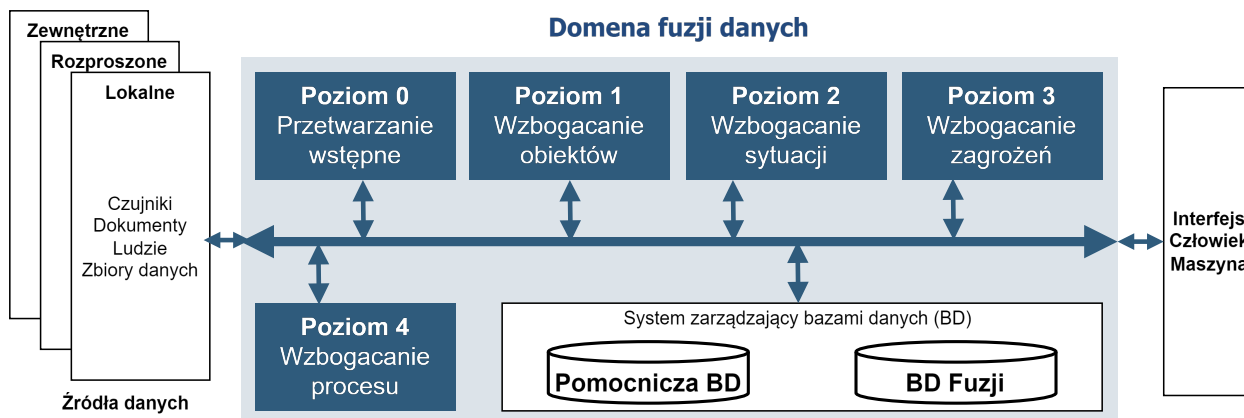
## 5.1 Model fuzji danych „Joint Directors of Laboratories” (JDL)

Jednym z najczęstszych modeli fuzji danych obecnych w literaturze jest model JDL, który klasyfikuje metody fuzji na bazie wejść i wyjść procesu, a swoje podstawy zawdzięcza wczesnym zastosowaniom w aplikacjach wojskowych. Podstawowa wersja modelu JDL wyróżnia cztery poziomy abstrakcji: obiekt, sytuacja, wpływ, udoskonalenie procesu [148].

Jak wspomina Khalegi i inni w [148] pomimo swojej popularności, model JDL posiada wiele wad, które wynikają m.in. z ugruntowania algorytmu w przemyśle wojskowym. Ze względu na swoje ograniczenia na przestrzeni ostatnich dekad zaproponowano wiele modyfikacji pozwalających lepiej go dostosować do potrzeb aplikacyjnych.


Pierwotny model JDL jest przedstawiony na rysunku 5.3. Jak można zauważyć, przedstawia on pięć poziomów fuzji [149]:

- Poziom 0 – przetwarzanie sygnałów wejściowych;
- Poziom 1 – estymacja i predykcja stanów obiektów na podstawie ich obserwacji;
- Poziom 2 – szacowanie i przewidywanie stanów obiektów na podstawie podstawowych zależności pomiędzy tymi obiektami;
- Poziom 3 – estymacja i przewidywanie efektów planowanych działań lub przewidywanych zachowań obiektów w otoczeniu, na sytuację, w której się znajdują;
- Poziom 4 - adaptacyjne przetwarzanie i akwizycja danych związana z zarządzaniem zasobami i udoskonalaniem procesu.



Rysunek 5.3: Model JDL. Ilustracja zainspirowana przez [149].

Według społeczności związanej z przemysłem samochodowym model JDL wymaga modyfikacji, aby był adekwatny do wieloczuJNIKOWYCH systemów obecnych w pojazdach. Jedną z modyfikacji jest wyodrębnienie poziomu 4, który nie przynależy do procesu fuzji. Kolejną modyfikacją jest wprowadzenie interfejsów człowiek-maszyna do procesów fuzji, co wskazuje na zmianę w podejściu do roli człowieka w systemie fuzji. W pierwotnych zastosowaniach fuzji skupiano się na eliminacji wpływu człowieka na proces decyzyjny, natomiast obecne badania skupiają się na zintegrowaniu działań człowieka z systemem [149]. Trend ten jest widoczny szczególnie w kontekście pojazdów autonomicznych, gdzie pomimo eliminacji sterowania samochodem przez człowieka, kluczowym dla systemu będzie nie tylko bezpieczeństwo i sprawne działanie, ale też samopoczucie i komfort pasażerów. W związku z tym samochód autonomiczny, powinien nie tylko monitorować stan zdrowia pasażerów, ale też ich zachowanie i dostosować swoje manewry, tak by nie powodowały one dyskomfortu u pasażerów na nie wrażliwych, a w konsekwencji sprawiały, że pasażerowie mają zaufanie do działania systemu i chcą jeździć takim samochodem. Udoskonalony model JDL, który uwzględnia wcześniej wymienione zmiany został opisany przez Lytrivisa i innych w [149]. Model ten jest przedstawiony na ilustracji 5.4. Opis poszczególnych elementów modelu przedstawiony jest w kolejnych podsekcjach.



Rysunek 5.4: Zaktualizowany model JDL do zastosowań motoryzacyjnych. Ilustracja zainspirowana przez [149].

### 5.1.1 Wzbogacanie obiektów

Wzbogacanie obiektów znajduje się w pierwszym poziomie modelu JDL, a w jego udoskonalonej wersji jest kluczowym elementem warstwy percepcji. Jego zadaniem jest estymacja stanów fizycznych obiektów, które w kontekście algorytmów percepcji najczęściej oznaczają innych uczestników ruchu drogowego, tj. samochody, rowerzystów, pieszych [149]. Może także dotyczyć estymacji parametrów drogi oraz potencjalnych przeszkód np. ocena czy krawężnik jest wystarczająco niski, by przez niego przejechać lub czy obiekt, w kierunku którego zmierza pojazd jest wiaduktem, pod którym można przejechać (zarówno z powodu ograniczeń prawnych, jak i fizycznych, tj. szerokości i wysokości obiektu).

Wzbogacenie obiektów, w zależności od architektury fuzji, może przyjąć różne formy, ale jednymi z najczęściej występujących części w przypadku popularnej architektury fuzji rozproszonej są metody:

- wstępnego przetwarzania pomiarów;
- śledzenia obiektów na poziomie sensora;
- czasowego i przestrzennego wyrównania pomiarów;
- asocjacji śledzonych obiektów;
- fuzji śledzonych obiektów;
- estymacji geometrii drogi.

#### Wstępne przetwarzanie pomiarów

W zależności od użytych czujników wymagane mogą być różne metody wstępnej obróbki danych pomiarowych, które pozwolą na ich użycie w algorytmach wyższego poziomu [149]. Jednym z przykładów takich zastosowań może być dealiasing prędkości dopplerowskiej detekcji, segmentacja pomiarów i wstępne ich zgrupowanie, a także wstępna klasyfikacja detekcji radarowych rozróżniająca je na te pochodzące z obiektów ruchomych lub potencjalnie nieruchomych. Na tym etapie otrzymane wyniki pomiarów mogą zostać skalibrowane o dostępne wartości kalibracyjne np. w przypadku algorytmów usuwanie zniekształceń obiektywu w kamerach lub stabilizujących obraz, lub w przypadku adiustacji pomiarów kątowych radaru.

#### Śledzenie obiektów na poziomie sensora

Ta funkcja odnosi się do zestawu operacji, które pozwalają na dostarczenie dalszym elementom systemu hipotezy stanów obiektu. Lokalizacja tej funkcjonalności w architekturze może różnić się w zależności od jej typu, natomiast komponenty stosowane w jej obrębie powstają zwykle bardzo podobnie i składają się z:

- przesiewania informacji wejściowych (*ang. gating*), która polega na ograniczeniu pomiarów tylko do tych, które mogą być związane ze wzbogaconym obiektem;
- asocjacji danych wejściowych do obiektu;
- filtrowania;

- zarządzania śledzonymi obiektami.

Kluczowym elementem algorytmów śledzenia obiektów jest wybranie właściwego modelu ruchu, który poprawnie oddaje zachowanie obiektu. Odpowiedni model pozwoli na znaczące zwiększenie precyzji estymat, a także jeśli zostanie umiejętnie dobrany może ograniczyć złożoność obliczeniową predykcji. Jednymi z najpopularniejszych modeli ruchu są [150], [151]:

1. Model stałego przyspieszenia (ang. *constant acceleration*, CA) zakładającym, że stan przyspieszenia obiektu nie podlega zmianie w czasie. Dla jednowymiarowej pozycji ( $x$ ), wektor stanu w chwili  $k$  tego modelu jest równy  $\mathbf{X}_k = [x \quad \dot{x} \quad \ddot{x}]'$ , a jego macierz przejścia dana jest wzorem:

$$\mathbf{F} = \begin{bmatrix} 1 & \Delta t & \frac{1}{2}\Delta t^2 \\ 0 & 1 & \Delta t \\ 0 & 0 & 1 \end{bmatrix}. \quad (5.1)$$

W modelu tym zakładane jest, że zryw, czyli zmiana przyspieszenia w czasie, jest szumem białym będącym zakłóceniem procesu. Oczekiwana wartość stanu  $\mathbf{X}_{k+1}$  przesunięta w czasie o  $\Delta t$  może być opisana za pomocą równania  $\mathbf{X}_{k+1} = \mathbf{X}_k \mathbf{F} + \mathbf{w}_k$ , gdzie  $\mathbf{w}_k$  jest szumem procesu.

2. Model stałej prędkości (ang. *constant velocity*, CV), rozważając jednowymiarową pozycję i stan  $\mathbf{X}_k = [x \quad \dot{x}]'$ , jego macierz przejścia wyniesie:

$$\mathbf{F} = \begin{bmatrix} 1 & \Delta t \\ 0 & 1 \end{bmatrix}, \quad (5.2)$$

który z kolei zakłada, że przyspieszenie obiektu jest szumem procesu, dzięki czemu wymaga mniejszej mocy obliczeniowej, a może okazać się wystarczający w przypadku sensorów dostarczających jedynie pomiaru pozycji lub znacząco zaszumionych pomiarów prędkości. Oczekiwana wartość stanów w chwili  $k + 1$  jest estymowana w taki sam sposób jak w przypadku modelu CA.

3. Model skoordynowanego skrętu (ang. *Coordinated Turn*, CT), w którym zakłada się że pojazd porusza się ze stałą prędkością i stałym kątem skręcenia kierownicy, a zmiany tych stanów są związane z szumem procesu. Dla stanu  $\mathbf{X}_k = [x \quad y \quad v \quad \phi \quad \omega]'$ , w którym  $x, y$  oznacza dwuwymiarową pozycję obiektu,  $v$  jego prędkość,  $\phi$  orientację, a  $\omega$  prędkość obrotową, równanie stanu przyjmie postać:

$$\mathbf{X}_{k+1} = f_{CT}(\mathbf{X}_k) + \mathbf{G}_{CT}\mathbf{w}_k, \quad (5.3)$$

gdzie:

$$f_{CT}(\mathbf{X}_k) = \begin{bmatrix} x + \frac{2v}{\omega} \sin \frac{\omega\Delta t}{2} \cos(\phi + \frac{\omega\Delta t}{2}) \\ y + \frac{2v}{\omega} \sin \frac{\omega\Delta t}{2} \sin(\phi + \frac{\omega\Delta t}{2}) \\ v \\ \phi + \omega\Delta t \\ \omega \end{bmatrix}, \quad (5.4)$$

$$\mathbf{G}_{CT} = \begin{bmatrix} 0 & 0 & \Delta t^2 & 0 & 0 \\ 0 & 0 & 0 & \frac{\Delta t^2}{2} & \Delta t^2 \end{bmatrix}, \quad (5.5)$$

$$\mathbf{w}_k = \begin{bmatrix} w_v & w_\omega \end{bmatrix}' \quad (5.6)$$

Komponenty  $w_v$  oraz  $w_\omega$  oznaczają odpowiednio szum związany z prędkością liniową oraz obrotową obiektu.

Śledzenie obiektów na poziomie sensora musi wykonać asocjację pomiaru do obiektów. Jednymi z popularnych algorytmów są metody:

- globalnego najbliższego sąsiada, który dąży do minimalizacji odległości pomiędzy obiektami a pomiarami;
- wspólna probabilistyczna asocjacja danych (ang. *Joint Probabilistic Data Association*, JPDA), która jest znacznie bardziej skomplikowana, gdyż oblicza najbardziej prawdopodobne rozwiązanie, uwzględniając niepewności pomiarów.

Kolejnym krokiem śledzenia obiektów jest decyzja o tym czy istniejące hipotezy obiektów powinny zostać utrzymane w algorytmie śledzącym, kiedy istnieje pomiar potwierdzający jego istnienie. Jeśli hipoteza obiektu nie uzyskuje potwierdzenia poprzez istnienie nowych, zasocjowanych dla niej pomiarów, to konieczne może stać się jej usunięcie. Z kolei pomiar oddalony od śledzonych obiektów, w szczególności jeśli posiada małą niepewność, lub grupa potwierdzających się wzajemnie pomiarów, powinien skutkować stworzeniem nowego obiektu.

Ostatnim krokiem algorytmów śledzenia obiektów jest filtrowanie i predykcja, w trakcie której uzyskane obiekty oraz przypisane do nich pomiary zostają poddane filtracji oraz predykcji. W trakcie tego kroku zostaje wykorzystany wybrany model ruchu, który pozwala na predykcję stanów oraz zaaplikowanie wybranych metod estymacji, które najczęściej są filtrem Kalmana dla modeli liniowych lub jednym z jego wariantów, takich jak rozszerzony filtra Kalmana (ang. *Extended Kalman Filter*, EKF), lub niesprzężony filtr Kalmana (ang. *Unscented Kalman Filter*, UKF) dla modeli nieliniowych.

### Wyrównanie przestrzenne i czasowe

Śledzone obiekty wyestymowane przez sensor muszą zostać umieszczone w układzie współrzędnych, który jest wspólny dla wszystkich czujników w pojeździe, tak by możliwa była prawidłowa ocena otoczenia. Wykonanie wyrównania przestrzennego jest możliwe tylko jeśli posiada się informacje o położeniu i orientacji sensora w odniesieniu do wspólnego punktu referencyjnego. Panagotis i inni w [149] podają, że najczęściej stosowanym początkiem samochodowego układu współrzędnych (ang. *Vehicle Coordinate System*, VCS) jest środek geometryczny pojazdu, jednak w wielu przypadkach stosuje się łatwiejszy do wyznaczenia środek tylnej osi, którego zastosowanie dodatkowo ułatwia przekazanie zmian pozycji punktów na pojeździe, ze względu na pokrycie się początku układu współrzędnych z osią obrotu pojazdu.

### Asocjacja śledzonych obiektów

Po sprawdzeniu śledzonych obiektów do wspólnego układu współrzędnych należy zweryfikować czy niektóre z obiektów nie są reprezentowane przez wyniki obserwacji z wielu sensorów. Do takiej sytuacji dochodzi na pokrywających się obszarach pola widzenia. Do takiego zdarzenia może też dojść gdy obiekt

opuścił pole widzenia jednego z sensorów, ale jego hipoteza nie została jeszcze usunięta, przez co system dalej przewiduje jego położenie na podstawie wcześniej wyznaczonych parametrów.

Istnieją różne metody pozwalające na wykorzystanie informacji z kilku sensorów, tak aby udoskonalic informację o stanach śledzonego obiektu. W przypadku gdy istnieje wiele jednoczesnych obserwacji metoda *Lagrange relaxation* (relaksacji Lagrange'a) może okazać się skuteczna. W niektórych wypadkach, w szczególności kiedy dostępne są pomiary o dużej niepewności najlepiej mogą się sprawdzić metody probabilistyczne oraz takie, które bazują na dobranych a priori wartościach granicznych asocjacji, opisane m.in. przez Bar-Shaloma w [150].

### **Fuzja na poziomie śledzonych obiektów**

Istnieje wiele metod fuzji dwóch obiektów opisanych przez stany oraz powiązane z nimi kowariancje. Są to między innymi metody:

- prostej fuzji, która zakłada brak korelacji pomiędzy łączonymi obiektami;
- ważonej kowariancji, która daje dobre rezultaty gdy dostępne są wiarygodne estymaty śledzonych obiektów i która pozwala na minimalizację wpływu nadmiarowej informacji;
- „covariance union”, która wymaga dużej mocy obliczeniowej, ale pozwala na redukcję degradacji estymat w obecności fałszywych informacji wejściowych.

W zależności od jakości informacji wejściowej może okazać się, że wystarczające będzie założenie stałych wag dla niepewnych estymat obiektów [149]. Z tego powodu wybór odpowiedniego algorytmu fuzji jest wielokryterialnym przedsięwzięciem, które wymaga przemyślanego wyboru z uwzględnieniem cech środowiska drogowego, dostępnej mocy obliczeniowej, szumu procesu, korelacji pomiarów i założeniach dotyczących ich niezależności.

### **Estymacja geometrii drogi**

Celem algorytmów fuzji w zastosowaniach samochodowych jest również estymacja parametrów drogi oraz obiektów niebędących pojazdami m.in. w celu przewidywania optymalnych manewrów, dostosowania prędkości do krzywizny drogi, oceny przejezdności potencjalnych przeszkód oraz algorytmów jednoczesnego mapowania i lokalizacji. Istnieją różne algorytmy, które umożliwiają realizację takich celów, wśród nich można wyróżnić:

- estymację geometrii drogi za pomocą kłoidów lub krzywych B-sklejanych na podstawie pomiarów sensorów;
- ekstrakcję parametrów drogi na podstawie dokładnych map, pobieranych dla bliskiego otoczenia pojazdu i pomiarów GPS.

Informacje uzyskane w wyniku powyższych metod, których wynikiem są różne hipotezy kształtu otoczenia o różnej niepewności mogą zostać połączone zarówno ze sobą jak i z mapami wysokiej rozdzielczości, które również mogą być obciążone błędem wynikającym przede wszystkim z nieaktualnych

danych. W wyniku fuzji takich danych uzyskuje się informacje korzystne zarówno dla pojazdu jakimi są poprawiona lokalizacja (względem sygnału GPS), a także dystrybutora mapy (aktualizacja mapy i informacje o szybkozmiennych warunkach drogowych).

### 5.1.2 Wzbogacenie sytuacji

Wzbogacenie sytuacji jest drugim poziomem fuzji w modelu JDL, który skupia się na rozkładaniu zależności pomiędzy obiektami w otoczeniu. Często ten rodzaj fuzji określa się jako „fuzję wysokiego poziomu”, ponieważ nie działa ona zwykle na podstawowych informacjach z sensorów, tylko wykorzystuje wyjście z algorytmów fuzji niższego poziomu. Ta grupa algorytmów ma na celu ocenę otaczającej sytuacji, tak by odpowiedzieć m.in. na pytania [149]:

- Czy powolna grupa pojazdów w polu widzenia porusza się w korku?
- Czy trajektorie pojazdów w otoczeniu przecinają się?
- Czy istnieje ryzyko kolizji i jakie jest jej prawdopodobieństwo?

W fuzji wysokiego poziomu najpowszechniejsze są metody:

- systemów rozmytych;
- teoria prawdopodobieństwa Bayesa;
- teoria Dempstera-Shafera.

Najczęstszymi zastosowaniami fuzji wysokiego poziomu są:

- przewidywanie trajektorii pojazdów;
- wykrywanie manewrów;
- przewidywanie zamiarów kierowcy;
- przyporządkowanie obiektów do pasa ruchu;
- szacowanie warunków drogowych.

### Przewidywanie trajektorii pojazdu

Celem tej grupy algorytmów fuzji jest ocena trajektorii pojazdu na podstawie jego obecnych stanów oraz źródeł z czynników eksteroreceptywnych. Realizacja tego zadania opiera się na implementacji trzech części fuzji:

- aplikacja stanów kinematyki pojazdu lub grupy modeli, na podstawie których zostanie dokonana predykcja;
- predykcja trajektorii na podstawie informacji o geometrii drogi, przy założeniu, że kierowca będzie starał się utrzymać pojazd w obrębie obecnego pasa ruchu;

- połączenie informacji z tych dwóch części tak aby otrzymać najbardziej prawdopodobną estymację.

Łączenie informacji z dynamiki pojazdu oraz geometrii drogi, w celu przewidzenia jego trajektorii może być procesem złożonym. Jak wskazuje Latravis i inni w [149] użycie informacji o kinematyce pojazdu daje najlepsze rezultaty w predykcji krótkoterminowej, a w dłuższym okresie czasu trajektoria pojazdu zwykle podąża za geometrią drogi.

### Wykrywanie manewrów

Wykrywanie manewrów ma na celu ocenę, która spośród wykonywanego zestawu akcji, jest wykorzystywana przez kierowcę. Przykładowy zestaw akcji przedstawiony jest w [149] i obejmuje on:

- swobodny ruch;
- zmianę pasa;
- wyprzedzanie;
- podążanie za innym pojazdem.

Panagiotis i inni w [149] jako właściwą metodę implementacji uważają metodę Dempstera-Shafera, która jest w stanie wyestymować obecny manewr wykonywany przez kierowcę. Za źródła informacji w podanym przykładzie mogą posłużyć:

- czas potrzebny do przekroczenia linii pasa ruchu, z zachowaniem trajektorii;
- dystans do najbliższej linii pasa ruchu;
- czas potrzebny do przekroczenia najbliższej linii;
- kształt drogi;
- krzywizna trajektorii pojazdu oraz odległość do poprzedzającego pojazdu.

Dla każdego z wybranych źródeł informacji przypisywana jest estymowana wiarygodność, która pozwala oszacować najbardziej prawdopodobną, w obecnym momencie, akcję. Należy zaznaczyć, że metoda ta bazuje na wyciąganych na podstawie obserwacji wnioskach, w związku z czym jej wynikiem jest pozorne prawdopodobieństwo, które może znacznie różnić się od rzeczywistego. W większości przypadków nie jest jednak możliwe uzyskanie prawdopodobieństwa pomiaru w rozumieniu matematycznym, a jego oszacowanie za pomocą wyżej wymienionej metody może dawać wystarczające rezultaty.

### Wykrywanie zamiarów kierowcy

Funkcjonalność polegająca na przewidywaniu zamiarów kierowcy może być kluczowa do właściwej oceny sytuacji, w której znalazł się samochód. W przypadku, kiedy kierowca straci koncentrację lub w wyniku błędu przekroczy linię pasa drogowego system może właściwie ocenić, że nie jest to zamierzony manewr wyprzedzania i autonomicznie skorygować tor pojazdu czy ostrzec sygnałem dźwiękowym kierowcę o niebezpieczeństwie.

### Przyporządkowanie obiektów do pasa ruchu

Ten algorytm fuzji ma na celu ocenę pasa ruchu otaczających pojazdów, tak aby ocenić przewidywaną trajektorię innych uczestników ruchu drogowego względem pojazdu autonomicznego (ego). Informacja o kształcie drogi i znajdujących się na niej pasach w połączeniu z informacją o tym czy pobliski samochód porusza się po oczekiwanej trajektorii względem przypisanego pasa ruchu jest ważna do oceny ryzyka kolizji oraz planowania manewrów.

W [149] przykładowe źródła informacji pozwalające na ocenę pasa to:

- przysze przesunięcie obiektów względem pojazdu ego bazujące na predykcji trajektorii wykorzystujących wybrane modele ruchu pojazdu;
- odległość wykrytego obiektu względem pojazdu ego.

### Szacowanie warunków drogowych

Fuzja wysokiego poziomu pozwala na obserwację zachowania obiektów w okolicy i estymację na podstawie ich obserwacji stanu otoczenia. Panagiotis i inni za przykłady takich funkcji podają [149]:

- ocenę zatłoczenia drogi (np. małe, średnie, duże, korek, blokada ruchu);
- ocenę nawierzchni i widoczności (mgła, deszcz, oblodzona droga).

## 5.2 Architektury fuzji danych

Kluczowym elementem projektowania systemów aktywnego bezpieczeństwa i jazdy autonomicznej jest ocena możliwości systemu lub, jeśli etap projektu na to pozwala, dostosowanie parametrów systemu w celu odpowiedniego dobrania architektury fuzji danych. Architektura systemu określa, jakie dane są scalane w samym sensorze, a jakie przesyłane do centralnej jednostki obliczeniowej lub propagowane do innych czujników. Dobór właściwego projektu musi uwzględnić szczegółową analizę możliwości obliczeniowych procesorów wbudowanych w obrębie sensora, ale także uwzględnić przepustowość kanałów komunikacji pomiędzy komponentami systemu. W przypadku komunikacji współdzielonej z innymi komponentami samochodu kluczowa jest ocena opóźnień i stabilności komunikacji w najgorszym scenariuszu, gdy wszystkie urządzenia starają się komunikować z największą dopuszczalną dla nich prędkością transmisji.

Wybór właściwej architektury fuzji jest kluczowy w przypadku projektowania systemów, które mają spełniać standardy bezpieczeństwa ASIL, określone w normie ISO 26262. Normy określające zachowanie systemów działających w warunkach wysokiego ryzyka spowodowania uszczerbku na ludzkim zdrowiu wymagają nie tylko wykrycia uszkodzenia danych na etapie transmisji, ale również oceny stanu czujnika, z którego informacje pochodzą. W zależności od rodzaju urządzenia pomiarowego analiza wiarygodności uzyskanych danych oraz stanu czujnika może wymagać znacznej ilości danych i mocy obliczeniowej, co sprawia, że wykonanie chociaż części obliczeń na poziomie sensora, tak by odciążyc główną jednostkę obliczeniową, wydaje się być bardzo atrakcyjnym rozwiązaniem.

W miarę rozwoju systemów samochodowych architektury fuzji wydają się przeplatać, a jeden system może składać się z komponentów zbudowanych w różnych architekturach, które dzielą jedną jednostkę obliczeniową, jednak poszczególne komponenty nadal zachowują układ opisany w 1997 roku przez Halla i Llinasa w [146] i może je rozdzielić na fuzję:

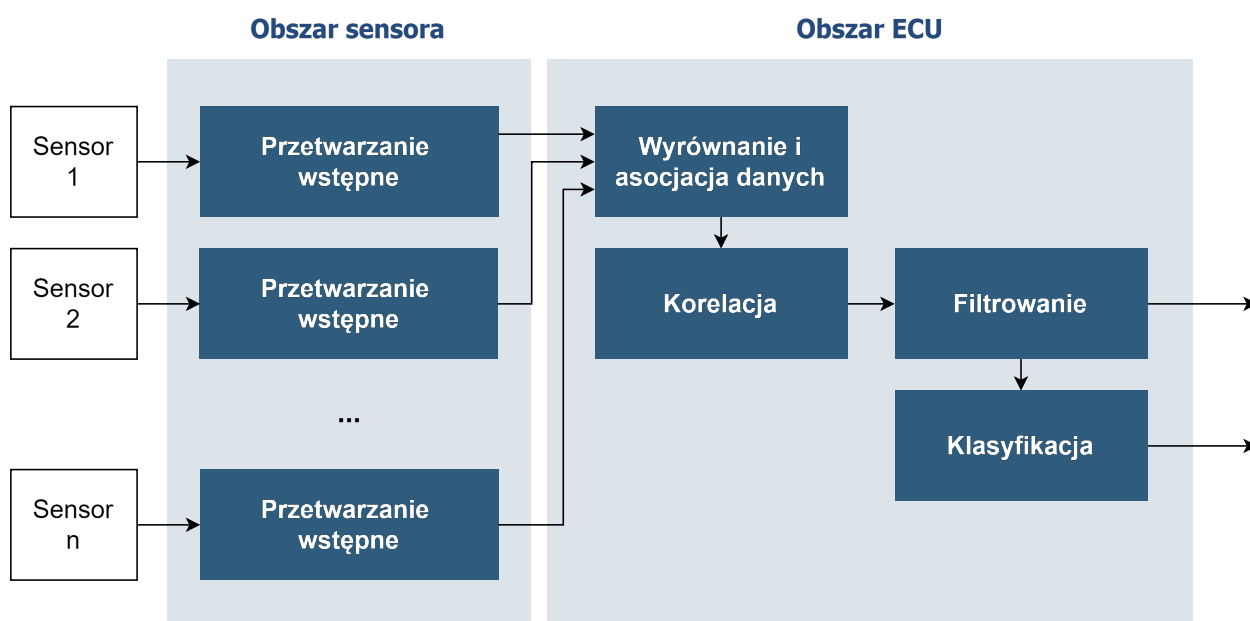
- scentralizowaną, przedstawioną na rysunku 5.5;
- rozproszoną (nazywaną również autonomiczną), przedstawioną na rysunku 5.6;
- hybrydową, przedstawioną na rysunku 5.7.

### 5.2.1 Architektura scentralizowana


Architektura scentralizowana przedstawiona jest na ilustracji 5.5. Polega ona na przesłaniu wszystkich użytecznych informacji do centralnej jednostki obliczeniowej. Na etapie sensora stosowana jest tylko podstawowa obróbka danych, która pozwala na ich użycie w jednostce obliczeniowej.

Po przesłaniu danych do jednostki obliczeniowej następuje transformacja pomiarów z układu współrzędnych sensora do układu stosowanego przez algorytm fuzji (do układu współrzędnych samochodowych lub globalnego układu współrzędnych). Gdy pomiary zostaną przedstawione we wspólnym układzie współrzędnych, następuje ich grupowanie, tak aby pomiary z każdej grupy przedstawiały jeden potencjalny obiekt.


Uzyskane grupy pomiarów stanowią zbiór bogatych, nieprzetworzonych informacji o obiektach, co w teorii może zapewnić najlepsze wyniki estymacji, przy założeniu, że dane zostały prawidłowo przetworzone, a także doszło do ich prawidłowego wyrównania przestrzennego i czasowego. Na ostatnim etapie zestawy pomiarów są wykorzystywane w algorytmach śledzenia i klasyfikacji.



Rysunek 5.5: Uproszczony schemat architektury centralnej, podzielonej na obszary obliczeń realizowanych przez procesory sensorów i ECU. Inspirowane [146].



Rysunek 5.6: Uproszczony schemat architektury rozproszonej, podzielonej na obszary obliczeń realizowanych przez procesory sensorów i ECU. Inspirowane [146].



Rysunek 5.7: Uproszczony schemat architektury hybrydowej, podzielonej na obszary obliczeń realizowanych przez procesory sensorów i ECU. Przerywane linie oznaczają opcjonalne połączenie, które może zostać zredukowane na etapie projektowania. Inspirowane [146].

### 5.2.2 Architektura rozproszona

Ilustracja 5.6 przedstawia architekturę rozproszoną, która charakteryzuje się tym, że każdy czujnik dokonuje estymacji stanów obiektów, bazując na własnych pomiarach. Uzyskane hipotezy obiektów, wraz ze stanami, przewidywaną trajektorią i innymi informacjami wysokiego poziomu oczekiwanymi przez jednostkę obliczeniową są jej dostarczane w celu ich agregacji i uwspólnienia układu współrzędnych.

W tej architekturze fuzji większość kosztów obliczeniowych ponoszona jest przez jednostki obliczeniowe w obrębie czujników, które są odpowiedzialne za wstępne przetwarzanie pomiarów oraz algorytmy śledzenia i klasyfikacji obiektów. Centralna jednostka obliczeniowa jest odpowiedzialna za dopasowanie przestrzenne i czasowe pomiarów pochodzących z różnych źródeł, opisujących jeden obiekt oraz ich ostateczną klasyfikację na podstawie wielu źródeł informacji.

Jak wspomniano w [146] ta architektura posiada wiele zalet m.in. uproszczenie obliczeń na poziomie ECU wynikające z działania na wektorach stanu, a nie na pełnym zestawie surowych danych oraz redukcję wymaganej przepustowości transmisji danych. Wspomniane korzyści niestety okupione są stratą danych, skutkującą zmniejszoną dokładnością w porównaniu do architektury scentralizowanej.

### 5.2.3 Architektura hybrydowa

Architektura hybrydowa przedstawiona na ilustracji 5.7 łączy w sobie elementy architektury scentralizowanej i rozproszonej. Uzyskane na poziomie sensora informacje o trajektoriach śledzonych obiektów wraz ze stanami są przesyłane do jednostki centralnej, tak jak w przypadku fuzji rozproszonej. Poza tymi informacjami do dyspozycji algorytmu fuzji na poziomie ECU mogą być również wybrane informacje z sensora, które w przypadku fuzji rozproszonej zostałyby utracone w wyniku kompresji informacji do wektora stanu.

### 5.2.4 Inne architektury fuzji

Istnieje również możliwość budowania systemu w inny sposób niż trzy wymienione wyżej architektury.. W wyniku analizy dostępnych zasobów sprzętowych może okazać się, że niektóre czujniki będą musiały pracować w trybie rozproszonym lub hybrydowym, podczas gdy inne będą mogły udostępniać centralnej jednostce obliczeniowej wszystkie informacje.

Architektury fuzji można również podzielić ze względu na typ łączonych danych. Hall i Llinas w [146] wyróżniają trzy takie architektury:

1. Fuzja na poziomie pomiarów – łącząca nieprzetworzone informacje pomiarowe z kilku sensorów;
2. Fuzja na poziomie cech – łącząca cechy obiektu uzyskane w wyniku poprzedzających algorytmów przetwarzających surowe dane;
3. Fuzja na poziomie decyzji – polega na połączeniu informacji z klasyfikacji wykonanej przez sensory w ostateczną decyzję.

## 5.3 Wyzwania algorytmów fuzji multisensorycznej

Odpowiednio zaprojektowany system fuzji danych może nieść za sobą wiele korzyści wspomnianych w poprzednich częściach tej rozprawy. Jednak ich osiągnięcie wymaga pokonania wielu przeszkód. W [148] Khalenghi i inni wymieniają następujące problemy, z którymi borykają się algorytmy fuzji.

1. **Niedokładność danych** – dane wejściowe do algorytmów fuzji są obciążone błędami pomiarowymi, a w niektórych przypadkach mogą zawierać nieistniejące, ale raportowane obiekty. W radarach przykładem takiego pomiaru może być obiekt, który jest spowodowany odbiciem samochodu od ściany lub

innego pojazdu. Algorytmy fuzji powinny uwzględniać niedokładności pomiarów i wykorzystywać redundancje danych do poprawienia wyników.

2. **Nieprawdziwe i odstające pomiary** – rzeczywiste pomiary z sensorów są narażone na działanie w warunkach sprzyjających powstawaniu fałszywych pomiarów. Przykładami takich sytuacji może być billboard ze znakiem „stop” lub zdjęciem samochodu, obserwowany przez kamerę samochodową czy radar obserwujący odbicie z bariery drogowej. W przypadku obu tych systemów skutkiem działania w takich sytuacjach może być powstawanie fałszywego obiektu lub alarmu. Aby przeciwdziałać wystąpieniu błędów w takich sytuacjach, konieczne jest korzystanie z informacji pochodzącej z wielu sensorów.
3. **Sprzeczne informacje** – dane przekazywane przez czujniki mogą w niektórych przypadkach się wzajemnie wykluczać. Jednym z nich może być przytoczone wcześniej wielokrotne odbicie fali radarowej od bariery wskazujące na istnienie samochodu w otoczeniu. System wizyjny obserwujący ten obszar wykluczy istnienie pojazdu w miejscu wskazywanym przez radar. Istnienie tego rodzaju sprzecznych informacji wymaga od algorytmów fuzji złożonego działania. Jeśli w tym przypadku algorytm będzie rozpoznawał kształt drogi oraz barier drogowych, to może być możliwe oznaczenie obszarów pola widzenia radaru, które są obciążone wysokim ryzykiem błędnych pomiarów. Ta informacja może z kolei posłużyć do nadania większej wiarygodności pomiarom wykonanym przez system wizyjny.
4. **Modalność danych** – grupy sensorów, których wyjścia należy połączyć, mogą zwracać bardzo podobne lub skrajnie różne informacje. W praktyce bardzo przydatne jest takie dobranie czujników, aby była możliwa asocjacja, t.j. aby część pomiarów pozwalała na uzyskanie pokrywających się informacji, umożliwiające stwierdzenie z dużą pewnością, które pomiary z różnych czujników wskazują ten sam obiekt.
5. **Korelacja danych** – pewne typy sensorów mogą podlegać podobnym zakłóceniom. Architektura fuzji oraz jej algorytmy powinny eliminować wpływ skorelowanych informacji. W tym przypadku problem można przedstawić na przykładzie systemu wielokamerowego, którego pola widzenia pozwalają na wspólną obserwację realistycznego plakatu reklamowego przyklejonego w pobliżu przejścia dla pieszych. Zakładając, że na plakacie znajduje się postać w proporcjach 1:1, istnieje pewne ryzyko wykrycia tej osoby jako przechodnia oczekującego na ustąpienie pierwszeństwa. Ponieważ kamery będą obserwować plakat z podobnej perspektywy, będą narażone na wystąpienie wzajemnie potwierdzających się fałszywych detekcji. System fuzji powinien zostać zaprojektowany w taki sposób, aby minimalizować ryzyko wzajemnego potwierdzenia się błędnych pomiarów.
6. **Wyrównanie danych** – do prawidłowego działania fuzji konieczne jest sprowadzenie danych lub wyników fuzji do wspólnego układu współrzędnych. Nieprawidłowa kalibracja sensorów wpływająca na niedokładne przekształcenie do wspólnego układu odniesienia może umożliwić zastosowanie systemu fuzji.
7. **Asocjacja danych** – śledzenie wielu celów, które jest konieczne w zastosowaniach samochodowych to zadanie znacznie bardziej skomplikowane, niż śledzenie pojedynczego obiektu znane z innych ga-

łęzi przemysłu. Jedną z podstawowych różnic pomiędzy tymi metodami jest odpowiednie dopasowanie danych, które może przybrać formę asocjacji pomiar – obiekt lub obiekt – obiekt. W przypadku otoczenia bogatego w obiekty położone w bliskiej odległości od siebie właściwe dopasowanie w obu tych przypadkach staje się zadaniem nietrywialnym.

8. **Wybór architektury** – właściwy dobór architektury jest kluczowym elementem, który może znacząco wpłynąć nie tylko na rozpatrywany system fuzji, ale również na działanie całego samochodu w przypadku współdzielenia części zasobów. Na etapie projektowania należy poddać analizie najgorszy scenariusz obciążenia zasobów wraz z marginesem bezpieczeństwa.
9. **Chronometraż działania** – algorytmy fuzji muszą łączyć dane z różnych typów czynników, które dokonują pomiaru z różną częstotliwością i w różnych chwilach czasowych. Dodatkowym aspektem jest opóźnienie wynikające z czasu przetwarzania i transmisji danych. Jednym z kluczowych zagadnień projektowania systemów fuzji jest zaprojektowanie mechanizmów pozwalających na uwspólnienie czasu dla wszystkich pomiarów zebranych w różnych chwilach czasowych. Do realizacji takiego zadania potrzebny jest mechanizm pozwalający na predykcję wartości pomiarów lub stanów obiektów do momentu najnowszego pomiaru. W zależności od architektury systemu konieczne może być również wdrożenie metod pozwalających na wykorzystanie pomiaru otrzymanego poza kolejnością (ang. „out-of-sequence measurement”). Ostatnim z kluczowych zagadnień związanych z przesunięciami czasowymi jest także zaprojektowanie mechanizmów fuzji, aby opóźnienie ich wyników było na akceptowalnym do wybranego zastosowania poziomie. W przypadku systemów aktywnego bezpieczeństwa i jazdy autonomicznej łączny czas reakcji systemu na sytuację na drodze jest parametrem kluczowym. W tych zastosowaniach projekt nie może być racjonalnie uzasadniony, jeśli jego opóźnienie nie jest znacząco mniejsze niż czas reakcji najlepszych kierowców, a optymalnie powinien być o kilka rzędów wielkości mniejszy.
10. **Obserwacje statycznych i dynamicznych obiektów** – w przypadku, gdy istnieje możliwość kontroli nad częstotliwością pomiaru lub dynamiczną kontrolą nad momentem akwizycji danych, korzystne może być zwiększenie częstotliwości pomiaru w przypadku obecności obiektów o szybko zmieniających się parametrach, nawet jeśli nastąpi to kosztem zmniejszenia częstotliwości próbkowania w obszarach, w których takich obiektów nie ma lub ich parametry zmieniają się wolniej. W niektórych przypadkach korzystne może być również przechowywanie historii pomiarów lub stanów w pamięci.
11. **Rozmiar danych** – łączenie ze sobą informacji z kilku czujników wiąże się z transmisją i przetwarzaniem znacznej ilości danych. Z tego powodu po raz kolejny kluczowy staje się wybór architektury adekwatny do możliwości systemu oraz jeśli to możliwe selekcji najwartościowszych pomiarów lub kompresji danych. Takie metody mogą pozwolić na redukcję opóźnień transmisji danych, zredukować zużycie łącza, a także w przypadku preselekcji danych zredukować obciążenie procesora.



## Rozdział 6

# Radary w motoryzacji


Historia radarów w motoryzacji sięga lat 60. ubiegłego wieku, kiedy po raz pierwszy zaczęto rozważać ich użycie, w celu wykrycia przeszkód przed pojazdem oraz implementację prostych mechanizmów AEB [152]. Pierwsze takie próby odbywały się w Stanach Zjednoczonych, Japonii oraz w Niemczech, a prototypy radarów były budowane na podstawie przełomowych w tamtych czasach technologii jakimi były diody Gunna [152].

Pierwsze anteny radarowe dla samochodów bazowały na sygnale o częstotliwości 10 [GHz] i 16 [GHz]. Rozwój techniki pozwolił na stopniowe zwiększanie częstotliwości, m. in. poprzez wykorzystanie bardziej zaawansowanych tranzystorów, które umożliwiły stosowanie sygnałów o częstotliwościach: 24 [GHz], 35 [GHz], 60 [GHz], a ostatecznie do powszechnie stosowanego dziś pasma 77-81 [GHz] [152].

Pierwsze radary, wykorzystujące możliwości pasma wysokich częstotliwości, wyprodukowane zostały w 1998 roku przez firmę Bosch. Pierwotnie wykorzystywały one diodę Gunna, jednak szybko zastąpiono ją przez technologię monolitycznych mikrofalowych układów scalonych (MMIC), wykorzystujących arsenek galu [153]. Wczesne projekty radarów cechowały się sporym wymiarem czujnika oraz wysokimi kosztami produkcji, a przełom w tej kwestii przyniosła technologia tranzystorów krzemowo-germanowych, która pozwoliła na zintegrowanie wielu kanałów radarowych w obrębie jednego układu scalonego [154]. W ostatnich latach popularność zyskuje użycie tranzystorów CMOS, które pozwalają na działanie w częstotliwościach sygnałów radarowych [152].

Przełom w możliwościach tranzystorów sprawił, że możliwe jest wytworzenie niskim kosztem układów, które mogą kontrolować złożone szyki antenowe, a co za tym idzie mieć większą kontrolę nad formowaniem wiązki radarowej. Obecnie stosowane radary wykorzystują umiejętne rozmieszczenie anten nadawczych i odbiorczych w szyku antenowym oraz sterowanie wiązką, co pozwala na znaczne polepszenie użytku w oczekiwanych kierunkach w porównaniu do tradycyjnych anten. W ostatnich latach miniaturyzacja układów MMIC pozwoliła na pojawienie się na rynku rozwiązań oferujących radar w formie kompletnych układów. Układy te mogą zostać przylutowane do powierzchni i oferować gotowy układ radarowy, który separuje obwody wysokich częstotliwości radiowych (mogących w przyszłości osiągać częstotliwości powyżej teraherca), od części związanej z układem obliczeniowym, którego linie wejść i wyjść operują zwykle w zakresie setek megaherców [152].

Nowa generacja radarów rozpowszechniła się dzięki zainteresowaniu rynku ADAS, co sprawiło, że rynek radarów, ze znikomego poziomu w 2010 roku, wzrósł do wielomiliardowych rocznych obrotów [152]. Wzrost ten został dodatkowo wzmocniony poprzez wprowadzenie wymagań bezpieczeństwa w ramach NCAP [152]. Na rysunku 6.1 można zauważyć jak wiele radarów jest potrzebne, aby zaimplementować złożony system ADAS. Pomimo badań wykazujących pewne nasycenie rynku ADAS, to znaczny potencjał kryje się w zapotrzebowaniu jakie może wygenerować wprowadzanie na rynek systemów AD [152].



Rysunek 6.1: Przykładowe obszary zastosowania radarów w systemach ADAS. Ilustracja inspirowana [155].


## 6.1 Anteny radarowe

Antena radarowa jest kluczowym elementem, który umożliwia nadawanie oraz odbieranie impulsu elektromagnetycznego, używanego do oceny odległości przeszkód oraz kąta, pod którym się znajdują. Wczesne projekty radarów samochodowych, zmuszone przez stan ówczesnej technologii, bazowały na dużych i ciężkich antenach, w praktyce będące blokiem skrawanego aluminium [152]. W późniejszych latach pojawiły się również projekty zawierające obracające się elementy mechaniczne, które pomimo korzystnych jak na tamte czasy parametrów nie cieszyły się popularnością ze względu na skomplikowany proces produkcji [152].

Dzisiejsze projekty anten w radarach samochodowych nie przypominają już topornych urządzeń sprzed dekad. Postęp technologiczny w zakresie tranzystorów oraz metod produkcji sprawił, że anteny radarowe przypominają swoim wyglądem pola lutownicze na układzie scalonym, a w przypadku niektórych dipoli lub anten mikropaskowych dla wysokich częstotliwości, mogą stać się trudne do zauważenia ze względu na swoje rozmiary, a przede wszystkim na bardzo małą szerokość. Producenci chronią swoją własność in-

telektualną, dlatego zdjęcia nowoczesnych anten nie są szeroko dostępne. Starsze projekty rozebrane przez amatorów elektroniki można znaleźć w źródłach internetowych oraz na ilustracjach 7, 9 i 13 w publikacji Waldschmidta i in. [152].

Aby polepszyć charakterystykę anteny i zwiększyć jej możliwości stosuje się tzw. szyki antenowe, które są specjalnie zaprojektowanymi zestawami promienników antenowych, umożliwiającym nadawanie sygnału ze sterowanymi opóźnieniami w poszczególnych częściach szyku. W praktyce umożliwia to sterowanie kierunkiem czoła wysyłanej fali elektromagnetycznej. Ilustrację takiego działania przedstawiono na rysunku 6.2.



Rysunek 6.2: Przykładowy szyk antenowy wraz z ilustracją formowania wiązki. Sterowane opóźnienie sygnału antenowego  $\varphi$ , opóźnia czoła fali pojedynczych anten w szyku (przerywana linia), sterując kierunkiem wynikowej wiązki radarowej (czerwona linia). Ilustracja inspirowana [156].


W zastosowaniach samochodowych można wyróżnić dwa główne typy radarów, które najczęściej są wspomniane w literaturze, a które można rozpoznać na rysunku 6.1 [157]:

- krótkiego zasięgu – stosowane najczęściej jako sensory narożne lub boczne, używane do funkcjonalności CTA oraz BSD, które cechują się szerokim horyzontalnym polem widzenia;
- długiego zasięgu – wykorzystywane jako sensory przednie lub tylne, posiadające zasięg sięgający kilkaset metrów i mniejszy zakres kątów działania, są wykorzystywane w ACC, FCW oraz RCW, które w szczególności w warunkach autostradowych, wymagają znacznego zasięgu od czujnika.

Poza wspomnianymi zastosowaniami, radary długiego zasięgu umieszczone na przodzie pojazdu mogą realizować funkcjonalność polegającą na ocenie przejezdności przeszkody, która wymaga oceny kąta elewacji. Pomiar kąta elewacji dostarcza wartościowych informacji o kształcie otoczenia i obiektów w nim rozmieszczonych, dlatego można się spodziewać, że coraz więcej projektów będzie skupiać się na wprowadzeniu takiej funkcjonalności.

Projektowanie anten radarowych wymaga specjalistycznej wiedzy i realizowane jest przy wsparciu metod symulacyjnych, które umożliwiają wcześniejsze estymowanie zdolności apertury [155]. Stosowane

obecnie techniki pozwalają na stworzenie szyku antenowego w taki sposób, aby znacząco zwiększyć możliwości anten [158]. Jedną z takich metod jest metoda MIMO (multiple input multiple output), która polega na umieszczeniu kilku elementów nadawczych, rozstawionych tak, aby zwiększyć drogę fali elektromagnetycznej powracającej do elementów odbiorczych [152]. Przykładowy mechanizm działania zilustrowany jest na rysunku 6.3. W przypadku stosowania jednego elementu nadawczego powracająca fala trafiałaby na elementy odbiorcze z fazami określonymi jako  $[0 \ \varphi \ 2\varphi \ 3\varphi]$ . Zastosowanie dodatkowej anteny TX2, oddalonej od anteny TX1 o czterokrotność odległości pomiędzy elementami RX, sprawia, że powracająca fala trafia na te same elementy odbiorczej z opóźnieniem  $[4\varphi \ 5\varphi \ 6\varphi \ 7\varphi]$ . Łącząc ze sobą powstałe opóźnienia faz, uzyskuje się łącznie 8 pomiarów przesunięcia fazowego [159].




Rysunek 6.3: Schemat ilustrujący zasadę działania anten wirtualnych. Fala pod kątem  $\zeta$  powraca z drogą dłuższą o odcinek zależny od odległości pomiędzy antenami nadawczymi ( $d$ ), co umożliwia zmierzenie sygnałów o przesunięciu w czasie w stosunku do sygnału referencyjnego. Ilustracja inspirowana [159].

Metoda MIMO, po odpowiednim umiejscowieniu elementów nadawczych i odbiorczych w szyku antenowym tworzy „wirtualne anteny”, które znacząco zwiększają możliwości radaru [152], [157], co obrazuje rysunek 6.4.

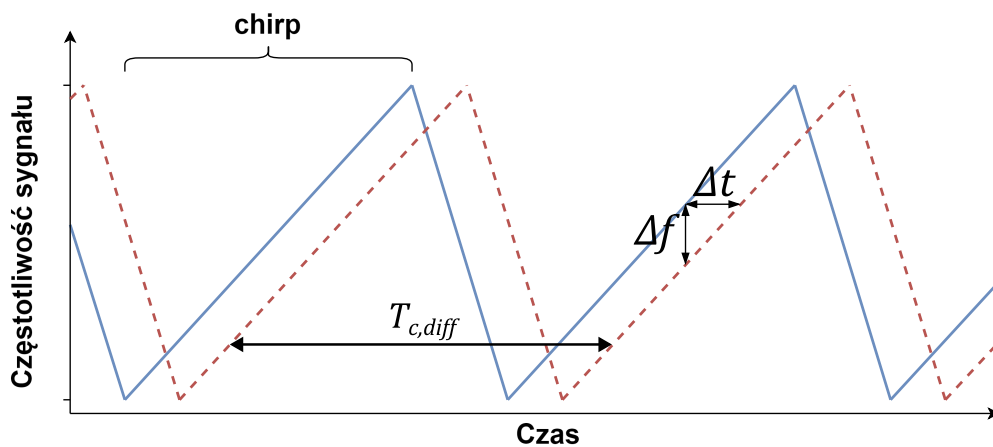
## 6.2 Fala ciągła z modulowaną częstotliwością

W zastosowaniach samochodowych najczęściej stosuje się radar z falą ciągłą z modulacją częstotliwości (FMCW, ang. *Frequency Modulated Continuous Wave*). Sygnał nadawany przez anteny w pojedynczym cyklu pomiarowym, nazywanym ramką (ang. *frame*) jest zestawem tzw. chirpów, czyli sygnałów o liniowo narastającej lub opadającej częstotliwości [160]. Przykładowy przebieg takiego sygnału można zaobserwować na rysunku 6.5.

Odpowiednio opóźniony chirp, jest transmitowany za pomocą zestawu anten, jak na rysunku 6.6. Powracające impulsy są odbierane przez anteny odbiorcze, a sygnał przez nie uzyskany jest mieszany



Rysunek 6.4: Schemat anten nadawczych (czerwone pola) i odbiorczych (niebieskie pola) w szyku antenowym, który przy użyciu technologii MIMO powoduje powstanie szyku wirtualnego (pola zielone). Inspirowane [157] oraz [158].



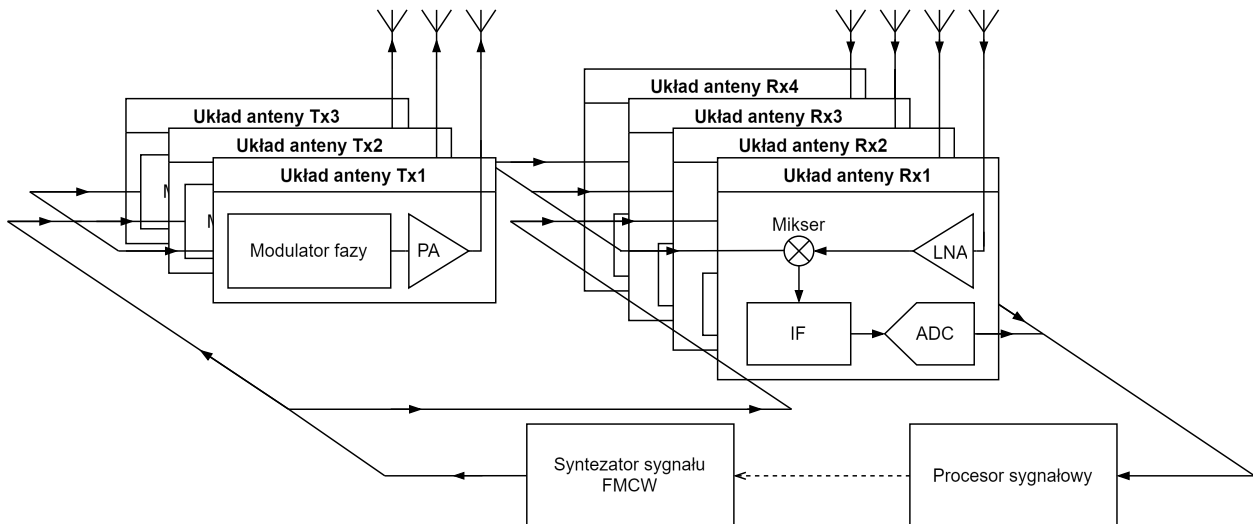
Rysunek 6.5: Wykres sygnału częstotliwości przedstawiający przykładowy sygnał referencyjny FMCW (linia niebieska) i oczekiwaną częstotliwość fali powracającej (czerwona przerywana linia). Inspirowane [160].

z sygnałem referencyjnym, używanym w antenach nadawczych. Rezultatem połączenia impulsów odebranych i referencyjnych (wysłanych) jest tak zwany sygnał pośredni, który następnie trafia do przetwornika analogowo-cyfrowego [160].

Sygnał cyfrowy przekazany do procesora sygnałowego jest zwykle złożony z superpozycji wielu odbić obiektów, których przetwarzanie zostanie omówione w następnej sekcji. Jeśli jednak rozważyć przypadek, w którym tylko jeden obiekt zwraca odpowiedź do anten odbiorczych, to odbierany chirp będzie miał przesunięcie czasowe  $\Delta t$  proporcjonalne do odległości  $r$  od sensora radarowego, co jest równoważne z przesunięciem częstotliwości  $\Delta f$ , obie wielkości pokazano na rysunku 6.5. W takim wypadku sygnał częstotliwości pośredniej obiektu będzie sinusoidą o częstotliwości  $\Delta f$ . Ta częstotliwość jest zdefiniowana jako [160]:

$$\Delta f = \frac{2rB}{c_0 T_c}, \quad (6.1)$$

gdzie  $B$  to szerokość pasma chirpa,  $T_c$  to czas trwania chirpa, a  $c_0$  to prędkość światła. Na podstawie tej zależności można uzyskać informację o odległości celu od radaru, stosując dyskretną transformację Fouriera obliczaną algorytmem FFT, który w tym kontekście określany jest jako *range-FFT* [160].



Rysunek 6.6: Uproszczony schemat radaru FMCW z trzema antenami nadawczymi i czterema antenami odbiorczymi. Inspirowane [160].

Każda ramka radarowa składa się z wielu chirpów. Wielokrotne powtarzanie chirpa jest konieczne do uzyskania estymacji prędkości obserwowanego obiektu w radarze FMCW [160]. Intuicyjnie można stwierdzić, że skoro jeden chirp wystarczy do uzyskania informacji o odległości obiektu od radaru, to dwa będą w stanie dostarczyć informację o dwóch pozycjach obiektu, a więc również o zmianie prędkości radialnej. Niestety bliskość tych dwóch pomiarów sprawia, że taka estymacja jest w większości przypadków niemożliwa, dlatego prędkość radialną obserwowanego obiektu ustala się na podstawie przesunięcia fazowego sygnału częstotliwości pośredniej dwóch następujących po sobie chirpów ( $\varphi_v$ ) za pomocą wzoru [160]:

$$v = \frac{\lambda \varphi_v}{4\pi T_{c,diff}}, \quad (6.2)$$

gdzie  $\lambda$  to długość fali nośnej (3,9 [mm] dla radaru 77 [GHz]), a  $T_{c,diff}$  to czas między chirpami. W praktyce prędkość, podobnie jak odległość, jest obliczana za pomocą FFT, co pozwala na znacznie większą precyzję pomiaru oraz rozróżnialność celów [160]. Ze względu na dwie transformaty Fouriera stosowane do ustalenia odległości i prędkości obiektu, ten krok często określa się jako dwuwymiarowe FFT (2D FFT).

Kolejnym kluczowym pomiarem wykonywanym przez radar jest kąt azymutu, a w niektórych urządzeniach również elewacja obserwowanego odbicia. W literaturze związanej z antenami i radarami często używane jest określenie „kąt przybycia” ( $\theta$ , AoA, ang. *Angle of Arrival*), który dla zestawu składającego się z dwóch anten odbiorczych może zostać wyznaczony na podstawie różnicy faz sygnałów obserwowanych na dwóch antenach ( $\varphi_\theta$ ) wzorem [160]:

$$\varphi_\theta = \frac{2\pi}{\lambda} r \sin \theta. \quad (6.3)$$


Aby zwiększyć precyzję pomiarów, radar FMCW wymaga zwiększenia liczby anten. Popularne radary są zbudowane z zestawu 3 anten nadawczych i 4 anten odbiorczych, co w przypadku umiejętnego ich zastosowania pozwala na działanie tak jakby był to sensor składający się z 12 anten odbiorczych. Zastosowanie odpowiedniego rozmieszczenia anten pozwala również na estymację kąta elewacji. Jak zauważa Vogginer i inni w [160] popularność zyskuje stosowanie czujników wyposażonych w 64, a nawet więcej anten.

Zwiększona liczba anten jest jednak problematyczna ze względu na konieczność odseparowania sygnałów z różnych nadajników, co znacząco zwiększa koszty takiego urządzenia.

### 6.3 Przetwarzanie sygnału w radarach FMCW

Przykładowy tor przetwarzania sygnału MIMO FMCW został przedstawiony na rysunku 6.7. Wejściami do algorytmów przetwarzania danych radarowych są sygnały o częstotliwości pośredniej z przetwornika ADC zebrane w ciągu jednej ramki. Oznacza to, że rozmiar danych stanowi macierz trójwymiarową, której kolejne wymiary to [160]:

- liczba anten odbiorczych;
- liczba chirpów dla pojedynczej anteny odbiorczej;
- liczba próbek z przetwornika ADC dla pojedynczego chirpa.



Rysunek 6.7: Schemat przetwarzania sygnału w radarach FMCW. Inspirowane [160].

Jak podaje Vogginger i inni w [160], stosowane przetworniki ADC zwracają zwykle próbki o 12-16 bitowej rozdzielczości, a w przypadku liczb przetworników zwracających liczbę zespoloną są to dwie 16-bitowe wartości. Spodziewany rozmiar macierzy danych to około 4 odbiorniki, 64 chirpy i 512 próbek, co dla rozważanego przypadku oznacza rozmiar 256 [kB] danych na każdą ramkę pomiarów radarowych.

#### 6.3.1 Mapa odległości i prędkości radialnej

Sygnał w obrębie surowej macierzy danych wejściowych stanowi bogate źródło informacji, które jest w obszarze zainteresowania wielu badaczy zajmujących się algorytmami radarowymi. Istnieje prawdopodobieństwo, że w przyszłości radary będą korzystały z sieci neuronowych działających bezpośrednio na tej warstwie. W teorii wyspecjalizowana sieć neuronowa mogłaby być w stanie nauczyć się rozpoznawania drobnych zmian w sygnale oraz pomiędzy antenami w celu zapewnienia znacznie większej dokładności niż

stosowane obecnie metody. W praktyce bardzo duża ilość danych oraz ich struktura sprawia, że większość publikacji z ostatnich lat podejmuje się działania na mapie odległości i prędkości radialnej, nazywanej w literaturze anglojęzycznej „Range-Doppler map” [160].

Jak wskazuje nazwa, mapa odległości i prędkości radialnej przedstawia informacje w postaci macierzy dwuwymiarowej, w której jedna oś jest związana z odległością obiektu odbijającego, a druga oś prędkością radialną. Wartościami macierzy są liczby zespolone będące wynikiem dyskretniej dwuwymiarowej transformacji Fouriera. W praktyce obliczenia polegają na wykonaniu dwóch następujących po sobie FFT [160]:

1. **Range-FFT** – oznacza szybką transformację Fouriera zastosowaną dla każdego chirpa w obrębie surowej macierzy danych wejściowych w celu uzyskania analizy sygnału pośredniej częstotliwości, która jest związana z odległością odbijającego obiektu równaniem (6.1).
2. **Doppler-FFT** – polegająca na zastosowaniu FFT na danych wyjściowych z Range-FFT na danych ze wszystkich chirpów w obrębie ramki radarowej. Pozwala to na uzyskanie liczb zespolonych, które są powiązane z relatywną prędkością radialną obserwowalnego obiektu za pomocą równania (6.2). Prędkość radialna uzyskana w ten sposób jest zależna od przesunięcia fazowego pomiędzy dwoma sygnałami. Wiąże się to z problemem niejednoznacznego określenia prędkości, które wynika z tego, że dla dużych prędkości obserwowanych obiektów, rzeczywiste przesunięcie fazowe sygnału pomiędzy dwoma falami może być większe niż jeden okres fali. Radary są zwykle projektowane tak, aby potrafiły w sposób jednoznaczny określić prędkość obiektów zbliżających się do pojazdu z prędkością co najmniej 150 [km/h] i oddalających od niego o 75 [km/h], ale szczególnie ze względu na przypadki autostradowe, gdzie relatywna prędkość samochodów może przekraczać 300 [km/h], należy weryfikować potencjalny aliasing algorytmicznie.

### 6.3.2 Kąt nadejścia

Kierunek odbitej fali radarowej można wyznaczyć działając na każdej komórce mapy Range-Doppler, bazując na różnicy w przesunięciach sygnału dla każdej anteny. Ze względu na mniejszy koszt obliczeniowy oraz akcelerację sprzętową obliczeń najczęściej stosuje się FFT. Wyjściami z tego algorytmu mogą być [160]:

- mapa odległości – kąta nadejścia;
- macierz odległość – prędkość radialna – kąt nadejścia;
- kąt nadejścia dla wykrytych obiektów.

### 6.3.3 Wykrywanie celów

Uzyskane mapy lub trójwymiarowa macierz uzyskane w wyniku algorytmów estymacji kąta nadejścia są zaszumione i posiadają znaczną ilość nadmiarowych informacji, związanych z istnieniem na nich obszarów, w których nie ma istotnych dla radaru obiektów. Aby dostarczyć dalszym algorytmom użytecznej informacji należy wykryć istotne obiekty i przekazać je do dalszych komponentów systemu. Dwie popularne metody stosowane w tym celu to [160]:

- CFAR — *Constant False Alarm Rate*, które w najprostszej wersji polega na wybraniu z uzyskanych map obszarów, w których amplituda przekracza wybraną wartość progową;
- Klasteryzacja/Grupowanie szczytów, która znajduje maksima obecne na mapach i wybiera spośród nich wcześniej zdefiniowaną liczbę.

Wynikiem działania algorytmu wykrywania celu mogą być:

- Punktowe detekcje radarowe – lista punktów o parametrach takich jak [160]:
  - Azymut;
  - Elewacja;
  - Odległość;
  - Prędkość radialna;
  - Amplituda;
  - RCS.
- Obszary na macierzy lub mapach wyjściowych z algorytmu kąta nadejścia, na których znajdują się wykryte obiekty.

#### 6.3.4 Klasyfikacja obiektów

Wykryte obiekty na mapie są przekazywane do algorytmów klasyfikacji, które mają za zadanie określić do jakiej klasy obiektów należy cel. Mogą to być np. samochody, ciężarówki, piesi, rowerzyści, budynki lub znaki drogowe. W przypadku tej części przetwarzania sygnałów radarowych rozróżnia się dwie grupy metodologii [160]:

- klasyczne algorytmy – oparte na maszynie wektorów nośnych, logice rozmytej lub kalibrowanych regułach, które klasyfikują obiekty na podstawie wybranych parametrów;
- uczenie maszynowe – metody oparte na sieciach neuronowych, najczęściej konwolucyjnych, które pozwalają na klasyfikację celu na podstawie jego reprezentacji na mapach lub macierzach wyjściowych z algorytmów kąta nadejścia.

#### 6.3.5 Śledzenie obiektów

Zgrupowane detekcje przypisane do jednego obiektu, mogą zostać użyte do oceny prędkości chwilowej obiektu i śledzenia jego stanów za pomocą algorytmów takich jak filtr Kalmana. W przypadku działania na fragmentach map możliwe jest zastosowanie sieci neuronowych do estymacji parametrów śledzonego obiektu [160].



## Rozdział 7

# Optymalizacja w kalibracji radarów

Kluczowym elementem rozwiązywania problemów w zakresie kalibracji radarów jest właściwe dobranie metody optymalizacyjnej, która pozwoli na znalezienie szukanych parametrów wybranego modelu matematycznego. Istnieje wiele metod optymalizacji, które w szerokim rozumieniu sięgają jeszcze III wieku p.n.e. i prób odnalezienia najkrótszej drogi przez Euklidesa, a której rozwój znacząco przyspieszył, gdy rozwój komputerów umożliwił ich implementacje algorytmiczne [161].

Podstawowym celem optymalizacji bez ograniczeń jest zminimalizowanie funkcji celu  $\ell$ , która przyjmuje  $N$  parametrów. Poprzez minimalizację określa się znalezienie punktu  $\mathbf{b}^*$ , który spełnia nierówność [162]:

$$\ell(\mathbf{b}^*) \leq \ell(\mathbf{b}) \text{ dla każdego } \mathbf{b} \text{ w otoczeniu } \mathbf{b}^*, \quad (7.1)$$

co zapisuje się również jako [162]:

$$\min_{\mathbf{b}} \ell(\mathbf{b}). \quad (7.2)$$

Zapis w równaniu (7.1) „ $\mathbf{b}$  w otoczeniu  $\mathbf{b}^*$ ” jest w tym wypadku kluczowy, ponieważ określa on minimalizację lokalną, która oznacza poszukiwanie minimum funkcji celu w pobliżu obecnego punktu. Oznacza to, że w przypadku funkcji celu, która posiada wiele ekstremów, minimalizacja lokalna nie będzie w stanie pokonać wzniesień, a jedynie odnaleźć najbliższe minimum [162]. Zachowanie to jest przedstawione na rysunku 7.1, gdzie optymalizowane parametry podążyły w kierunku minimum lokalnego funkcji.



Rysunek 7.1: Mapa poziomicowa przykładowej funkcji celu z minimum lokalnym z lewej strony oraz minimum globalnym z prawej. Ciemniejsze obszary oznaczają mniejsze wartości. Czerwona linia oznacza kierunek optymalizacji lokalnej równania z wartością początkową oznaczoną kropką.

Znalezienie lokalnego minimum funkcji celu, nazywanego również lokalnym optimum, w wielu przypadkach jest niewystarczające. Z tego względu dużą dziedziną optymalizacji są metody pozwalające na znalezieniu globalnego minimum funkcji celu, które można zapisać wzorem [162]:

$$\ell(\mathbf{b}^*) \leq \ell(\mathbf{b}) \text{ dla każdego } \mathbf{b}. \quad (7.3)$$

Wykonanie tego zadania jest znacznie trudniejsze i większość metod nie może zagwarantować znalezienia globalnego optimum. Rozwiązanie takiego problemu często jest skupione wokół generacji dużej liczby punktów początkowych, które następnie są na różnorakie sposoby rozprawdane po przestrzeni rozwiązań w poszukiwaniu lokalnego minimum. Kolejnym krokiem jest porównanie uzyskanych wartości funkcji celu dla populacji rozwiązań. W zależności od metody kolejne iteracje mogą się sprowadzać do tego, że jednostki o gorszych wynikach kontynuują poszukiwania w kierunku punktów które zarejestrowały lepsze rozwiązania. Przykładowe działanie algorytmu optymalizacji globalnej można zaobserwować na rysunku 7.2. Użycie w tym przypadku określeń takich jak „populacja” i „jednostka” jest celowe, ponieważ wiele algorytmów optymalizacji globalnej jest zainspirowanych naturą. Można to zauważyć między innymi w algorytmach takich jak algorytm optymalizacji roju oraz ewolucji różnicowej [163].

Szansę na znalezienie właściwego rozwiązania można poprawić poprzez właściwe zdefiniowanie granic obszaru poszukiwań. Pozwala to na zwiększenie gęstości punktów początkowych przy użyciu zdefiniowanego zbioru  $U \subset \mathbb{R}^N$ . W takim przypadku problem minimalizacji zostanie zapisany jako:

$$\ell(\mathbf{b}^*) \leq \ell(\mathbf{b}) \text{ dla każdego } \mathbf{b} \in U \text{ w otoczeniu } \mathbf{b}^*, \quad (7.4)$$


lub

$$\ell(\mathbf{b}^*) \leq \ell(\mathbf{b}) \text{ dla każdego } \mathbf{b} \in U \quad (7.5)$$


dla optymalizacji globalnej [162].

Prawidłowe dobranie parametrów jest kluczowe, gdy funkcja kosztu ma bardzo złożoną strukturę, posiadającą wiele lokalnych minimów, a także gdy występuje w niej powtarzalność, która może wynikać między innymi z wykorzystania funkcji trygonometrycznych. W takim wypadku konieczna jest analiza, pozwalająca na wykazanie parametrów, które wykluczają obszary zreplikowane przez okresowość funkcji kosztów, a także wszystkie obszary, których rozważanie nie ma uzasadnienia ze względu na założenia wynikające z racjonalności rozwiązywanego problemu. Dla przykładu można podać, że w przypadku optymalizacji próbującej wyznaczyć prędkość samochodu, sensowne wydaje się ograniczenie poszukiwań do wartości maksymalnej rozwijanej przez dany model (z zapasem bezpieczeństwa).


Jak można zaobserwować między innymi na rysunku 7.2, optymalizacja globalna wymaga znacznej liczby punktów startowych. Ze względu na wymagania pamięciowe oraz obliczeniowe, które przekraczają możliwości budżetowych procesorów sygnałowych, implementacja algorytmów optymalizacji globalnej ogranicza się tylko do działania post factum, które są wykonywane w celach badawczych. W przypadku metod działających na procesorach wbudowanych szczególną popularnością cieszy się optymalizacja lokalna z ograniczeniami, która przy odpowiednim doborze parametrów jest w stanie wykonać oczekiwane zadania w zakresie kalibracji radaru.




(a) Krok 1. Generacja wstępnej populacji.



(b) Krok 2. Minimalizacja lokalna każdego osobnika w populacji.



(c) Krok 3. Kolejna iteracja minimalizacji lokalnej dla każdego osobnika.



(d) Krok 4. Osobniki, które znalazły optimum lokalne są porównywane z innymi, a jeśli nie znajdują się w pobliżu minimum globalnego zostają usunięte.

Rysunek 7.2: Etapy wykonywania przykładowego algorytmu optymalizacji globalnej narysowane na mapie poziomowej. Ciemniejsze obszary oznaczają mniejsze wartości. Czerwone kropki przedstawiają populacje rozwiązań.

Algorytmy optymalizacji lokalnej można podzielić na algorytmy gradientowe, które wymagają znajomości pochodnych każdego parametru, oraz algorytmy bezgradientowe, które są w stanie rozwiązać równanie jedynie za pomocą funkcji kosztów. Metody bezgradientowe cieszą się opinią bardziej odpornych na szum pomiarów oraz duże uskoki w funkcji kosztów, które powodują wahania gradientu lub wręcz uskoki gradientu do nieskończoności. W przypadku metod gradientowych niewątpliwą zaletą jest znajomość spadku, co w niektórych zastosowaniach, np. w filtrach adaptacyjnych, może sprawić, że w jednej iteracji wystarczy wyliczyć wartość gradientu dla jednego punktu pomiarowego i wykonać krok w przeciwnym kierunku, aby zbliżyć się do optymalnej wartości. W tym zakresie wybór odpowiedniej grupy metod obliczeniowych, adekwatnej do zastosowania jest nietrywialny i wymaga przeprowadzenia testów na zbiorze danych zbliżonym do stosowanego.

W przypadku problemów liniowych lub kwadratowych, znalezienie optimum może się odbyć poprzez wykonanie jednego zestawu obliczeń, na przykład poprzez rozwiązanie układu równań metodą najmniejszych kwadratów. W wielu napotkanych problemach, do których zaliczamy także większość algorytmów kalibracji radaru, nie można dojść do rozwiązania w jednym kroku. Ich rozwiązanie można uzyskać tylko poprzez wykonanie wielu powtórzeń zestawu instrukcji, które z każdą iteracją przybliżają parametry do optimum. Iteracje te można zapisać równaniem [161]:

$$\mathbf{b}^{(n+1)} = \mathbf{b}^{(n)} + \Delta_{\mathbf{b}}, \quad (7.6)$$

gdzie  $\mathbf{b}^{(n+1)}$  oznacza wartość parametru w kolejnej iteracji ( $n + 1$ ),  $\mathbf{b}^{(n)}$  wartość obecnej iteracji, a  $\Delta_{\mathbf{b}}$  wyliczony krok, który przybliży parametr w kierunku optimum.

Istnieje wiele zaawansowanych metod optymalizacji jednak w tym rozdziale opisane zostaną tylko te wybrane ze względu na spełnianie wymagań projektu wdrożeniowego, jakimi była bardzo ograniczona pamięć RAM, ROM oraz mały czas wykonania na zestawie danych pomiarowych radaru. W miarę zwiększania mocy układów obliczeniowych zasadne może być rozważenie implementacji bardziej skomplikowanych algorytmów lub sieci neuronowych.

## 7.1 Metody bezgradientowe

Algorytmy bezgradientowe nazywane są również metodami bezpośredniego szukania, ponieważ do znalezienia rozwiązania wykorzystują jedynie wartości funkcji celu  $f$ , obliczone na zbiorze danych. W wyniku prac wdrożeniowych najbardziej wartościowymi metodami poszukiwania wartości parametrów kalibracyjnych radaru okazały się metody: sympleksu Nelder-Meada oraz algorytm Hooka-Jeevesa, które zostaną opisane w tym rozdziale.

### 7.1.1 Metoda Hooke'a–Jeevesa

Metoda Hooke'a–Jeevesa jest jedną z najmniej złożonych obliczeniowo metod optymalizacji bezgradientowej. W jej procesie można wyróżnić dwa etapy, którymi są [161], [162]:

- etap próbny (*ang. exploratory*);
- etap roboczy (*ang. pattern*).

Aby wykonać etap próbny na etapie projektowania algorytmu należy zdefiniować zbiór wektorów poszukiwań. Jest to zestaw rozważanych przemieszczeń  $\Delta \mathbf{b}_{hj_m}$  ( $m \in \llbracket 1, M \rrbracket$ ) od punktu  $\mathbf{b}^{(n)}$ , które na etapie próbnym są używane do przeszukiwania przestrzeni rozwiązań w celu znalezienia wartości funkcji celu mniejszej niż wartość obecna [162]. Wektorami przemieszczeń mogą być wersory w przestrzeni szukanych parametrów lub dowolny inny układ wektorów ortogonalnych [161]. Celem kroku próbnego jest więc znalezienie sumy przesunięć spełniających warunek:

$$\ell(\mathbf{b}^{(n)} \pm s \Delta \mathbf{b}_{hj_m}) \leq \ell(\mathbf{b}^{(n)}), \quad (7.7)$$

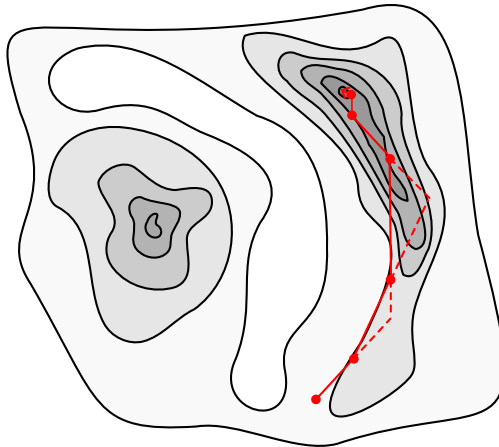
gdzie wstępne  $s = 1$ . Jeżeli nie udało się spełnić (7.7) dla żadnego  $\Delta \mathbf{b}_{hj}$ ,  $s$  jest zmniejszany w celu ograniczenia obszaru poszukiwań w dobranym zakresie  $s \in (0, 1]$ . Przykładowy zestaw wektorów poszukiwań dla przestrzeni dwuwymiarowej może zostać zdefiniowany jako:

$$\Delta \mathbf{b}_{hj} = \begin{bmatrix} \Delta \mathbf{b}_{hj1} \\ \Delta \mathbf{b}_{hj2} \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}. \quad (7.8)$$

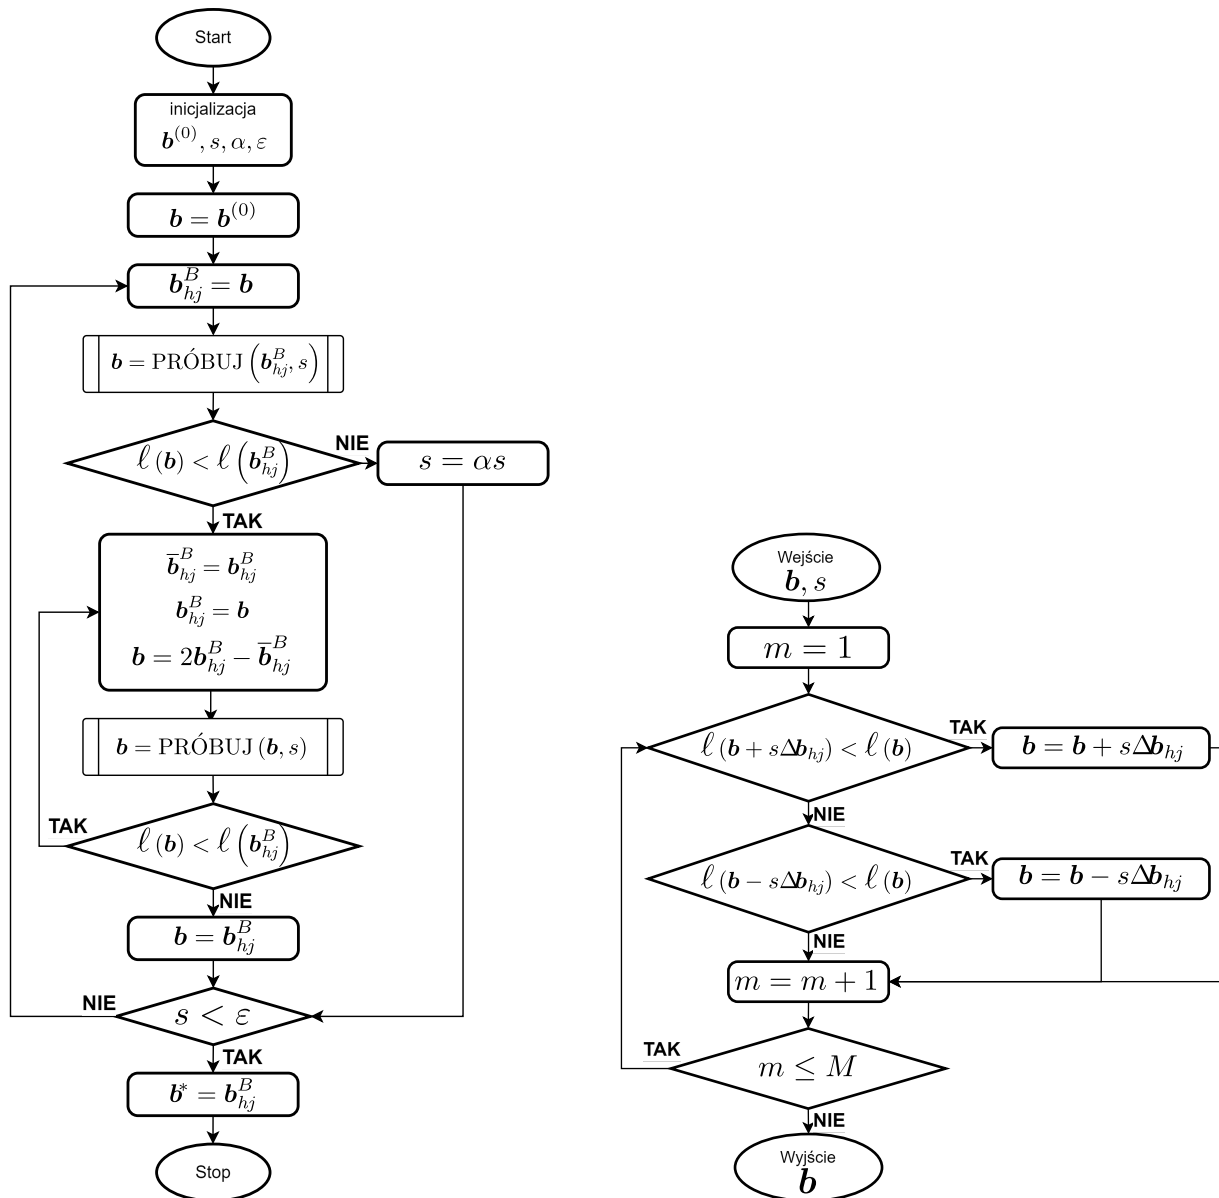
Etap próbny polega na sprawdzeniu kolejno wszystkich przemieszczeń  $\pm \Delta \mathbf{b}_{hj_m}$  wokół tzw. punktu bazowego  $\mathbf{b}_{hj}^B$  i aktualizowaniu pozycji w momentach, w których zostanie spełniony warunek (7.7). Jeśli nie uda się go spełnić następuje zmniejszenie wartości  $s$ . Poszukiwania mogą zostać przerwane, jeśli parametr  $s$  osiągnął już zdefiniowane minimum bez przyniesienia rezultatu lub osiągnięty został zdefiniowany limit prób.

Kiedy etap próbny przesunął parametry o wartości  $\pm \Delta \mathbf{b}_{hj_m}$ , które spełniły warunek (7.7), następuje przejście do etapu roboczego. W etapie roboczym stary punkt bazowy zostaje zapisany jako  $\bar{\mathbf{b}}_{hj}^B$ , a znalezione przemieszczenie parametru będące sumą przesunięć  $\pm \Delta \mathbf{b}_{hj_m}$  spełniających warunek, jest wykorzystywane do ustalenia nowego punktu bazowego  $\mathbf{b}_{hj}^B$ , do kolejnej iteracji poszukiwań. Schemat blokowy algorytmu przedstawiony jest na rysunku 7.4.

Przykładowa zbieżność algorytmu Hooke'a-Jeevesa pokazana jest na rysunku 7.3. Jak można na nim zauważyć, w pierwszej połowie drogi, jaką pokonały parametry największy udział miał etap roboczy, który znacząco przyśpieszył zbieżność parametrów do rozwiązania. W zademonstrowanym przykładzie można zauważyć, że skalowanie wektora przesunięć  $\Delta \mathbf{b}_{hj_m}$  za pomocą parametru  $s$  rozpoczęło się dopiero w najbliższym otoczeniu poszukiwanego rozwiązania.



Rysunek 7.3: Przykładowa zbieżność algorytmu Hooke'a-Jeevesa. Czerwone kropki oznaczają kolejne pozycje punktu bazowego. Linia ciągłą oznaczono przemieszczenie punktu bazowego  $\mathbf{b}_{hj}^B$ , linią przerywaną przemieszczenie punktu  $\mathbf{b}$  podczas zakończonych sukcesem kroków w etapie roboczym.



(a) Schemat blokowy głównej procedury algorytmu Hooke'a-Jeevesa.

(b) Schemat podprocedury PRÓBUJ algorytmu Hooke'a-Jeevesa.

Rysunek 7.4: Schemat blokowy algorytmu Hooke'a-Jeevesa. Inspirowany [161].

### 7.1.2 Metoda sympleks Nelder–Meada

Algorytm sympleksu Nelder–Meada w przeciwieństwie do metody Hooke’a–Jeevesa, nie korzysta z punktu bazowego i punktu roboczego, a z zestawu  $N + 1$  punktów ułożonych w sympleks, gdzie  $N$  jest liczbą poszukiwanych parametrów. W klasycznym podejściu utrzymuje się wierzchołki posortowane w kolejności od najlepszego do najgorszego. Dla  $N$  wymiarowej optymalizacji oznacza to [162]:

$$\ell(\mathbf{b}) \leq \ell(\mathbf{b}) \leq \dots \leq \ell(\mathbf{b}_{N+1}). \quad (7.9)$$

Z tego względu przyjmuje się, że  $\mathbf{b}_1$  oznacza najlepszy wierzchołek, a  $\mathbf{b}_{N+1}$  najgorszy.

Celem każdej iteracji tego algorytmu jest zastąpienie najgorszego wierzchołka punktem o wzorze:

$$\mathbf{b}(\mu) = (1 + \mu)\bar{\mathbf{b}} - \mu\mathbf{b}_{N+1}, \quad (7.10)$$

gdzie  $\bar{\mathbf{b}}$  jest środkiem ciężkości sympleksu z wyłączeniem najgorszego wierzchołka, danym wzorem:

$$\bar{\mathbf{b}} = \frac{1}{N} \sum_{i=1}^N \mathbf{b}_i. \quad (7.11)$$

Istnieją cztery wartości  $\mu$ :  $\mu_{ic}$ ,  $\mu_{oc}$ ,  $\mu_r$ ,  $\mu_e$ , które są używane w zależności od etapu algorytmu. Mogą one zostać dowolnie dobrane, ale muszą spełniać zależność [162]:

$$-1 < \mu_{ic} < 0 < \mu_{oc} < \mu_r < \mu_e \quad (7.12)$$

Najczęściej spotykanymi wartościami tych parametrów są [162]:

$$\{\mu_{ic}, \mu_{oc}, \mu_r, \mu_e\} = \left\{ -\frac{1}{2}, \frac{1}{2}, 1, 2 \right\} \quad (7.13)$$

Pierwszym zadaniem, jakie należy wykonać w algorytmie Nelder–Meada jest obliczenie wartości funkcji celu dla wszystkich jego wierzchołków oraz ich posortowanie jak w (7.9). Następnie, aż do momentu uzyskania warunków zatrzymania, dokonuje się iteracyjnego przetwarzania poniższych kroków [162].

1. **Obliczanie parametrów** – aktualizacja wartości:  $\bar{\mathbf{b}}$ ,  $\mathbf{b}(\mu_r)$ ,  $\ell_r = \ell(\mu_r)$
2. **Odbicie** – algorytm sprawdza czy w przypadku odbicia najgorszego punktu względem środka ciężkości sympleksu następuje poprawa wartości funkcji celu. Jeśli punkt  $\ell_r$  spełnia warunek:

$$\ell(\mathbf{b}_1) \leq \ell_r < \ell(\mathbf{b}_N), \quad (7.14)$$

to  $\mathbf{b}(\mu_r)$  zastępuje punkt  $\mathbf{b}_{N+1}$  i algorytm przechodzi do etapu sortowania.

3. **Ekspansja** – jeśli wartość uzyskana na etapie odbicia jest lepsza niż wartość obecnie najlepszego wierzchołka, to znaczy:

$$\ell_r < \ell(\mathbf{b}_1), \quad (7.15)$$

to następuje próba przesunięcia wierzchołka sympleksu do punktu  $\mathbf{b}_e = \mathbf{b}(\mu_e)$ , który jest bardziej oddalony od środka ciężkości sympleksu niż  $\mathbf{b}_r$ . Jeśli udało się spełnić warunek

$$\ell(\mathbf{b}_e) < \ell_r, \quad (7.16)$$

to punkt  $\mathbf{b}_{N+1}$  zostaje zastąpiony przez  $\mathbf{b}_e$ , a algorytm przechodzi do etapu sortowania.

4. **Zwężenie zewnętrzne** – dla spełnionego warunku:

$$\ell(\mathbf{b}_N) \leq \ell_r < \ell(\mathbf{b}_{N+1}), \quad (7.17)$$

następuje sprawdzenie, czy użycie w funkcji celu punktu pomiędzy punktem odbitym, a środkiem ciężkości ( $\mathbf{b}(\mu_{oc})$ ) da lepszy rezultat niż punkt odbity:

$$\ell(\mathbf{b}(\mu_{oc})) \leq \ell_r. \quad (7.18)$$

Jeśli warunek został spełniony, to  $\mathbf{b}_{N+1}$  zostaje zastąpiony przez  $\mathbf{b}(\mu_{oc})$ . algorytm przechodzi do etapu sortowania, jeśli nie, następuje przejście do etapu redukcji.


5. **Zwężenie wewnętrzne** – jeżeli odbicie nie poprawiło wyniku następuje próba użycia punktu pomiędzy obecnym najgorszym punktem  $\mathbf{b}_{N+1}$ , a środkiem ciężkości  $\bar{\mathbf{b}}$ , wyliczona przy użyciu współczynnika  $\mu_{ic}$ . Gdy uzyskana została wartość lepsza niż  $\ell(\mathbf{b}_{N+1})$ , dokonuje się zamiany  $\mathbf{b}_{N+1}$  przez  $\mathbf{b}(\mu_{ic})$  i algorytm przechodzi do etapu sortowania. W przeciwnym wypadku, następuje przejście do etapu redukcji.

6. **Redukcja** – wszystkie punkty, poza najlepszym  $\mathbf{b}_1$ , zostają przesunięte w jego kierunku za pomocą równania:

$$\mathbf{b}_i = \mathbf{b}_1 - (\mathbf{b}_i - \mathbf{b}_1), \forall i \in \llbracket 2, N + 1 \rrbracket. \quad (7.19)$$

7. **Sortowanie** – następuje ułożenie wszystkich wierzchołków, tak aby równanie (7.9) było spełnione.

Rysunek 7.5 przedstawia położenie wszystkich punktów rozważanych na poszczególnych etapach algorytmu Nelder-Meada. Należy przy tym zauważyć, że tylko część z nich jest wyliczana w jednej iteracji, co sprawia, że złożoność tego algorytmu jest nadal na akceptowalnym poziomie w przypadku wielu zastosowań na układach wbudowanych.



Rysunek 7.5: Sympleks stosowany w metodzie Nelder-Meada (niebieski), wraz z przedstawieniem środka ciężkości z wyłączeniem najgorszego punktu  $\bar{\mathbf{b}}$  oraz potencjalnych nowych punktów zastępujących  $\mathbf{b}_3$  na etapach: odbicia  $\mathbf{b}_r$ , ekspansji  $\mathbf{b}_e$ , zwężenia zewnętrznego  $\mathbf{b}_{oc}$ , wewnętrznego  $\mathbf{b}_{ic}$  oraz redukcji  $\mathbf{b}_z$ .

## 7.2 Metody gradientowe

Metody gradientowe są jednym z podstawowych narzędzi optymalizacji, które szczególnie dobrze sprawdzają się w przypadku funkcji o gładkim przebiegu. W przypadku tej dziedziny metod ważne jest, aby funkcja była różniczkowalna, co jest konieczne do wyznaczenia gradientu, czyli wektora pochodnych cząstkowych funkcji celu po szukanych parametrach, danego wzorem [161]:

$$\nabla \ell(\mathbf{b}) = \left[ \frac{\partial \ell(\mathbf{b})}{\partial b_1} \quad \frac{\partial \ell(\mathbf{b})}{\partial b_2} \quad \dots \quad \frac{\partial \ell(\mathbf{b})}{\partial b_n} \right]^T. \quad (7.20)$$

Algorytmy gradientowe składają się z dwóch elementów, wykonywanych w iteracjach, które przybliżają szukane parametry do rozwiązania. Mają one za zadanie [161]:

- Wyznaczanie kierunku spadku funkcji kosztów;
- Ustalanie długości kroku, jaki należy wykonać.

Metody gradientowe są bardziej podatne na szum parametrów oraz bardzo nieregularne funkcje celu, jednak posiadają również zaletę, jaką jest możliwość analitycznego wyznaczenia kierunku spadku funkcji celu. Optymalizacja gradientowa unika dzięki temu poszukiwań i wielokrotnych badań wartości funkcji celu, tak jak w przypadku metod bezgradientowych. Korzystanie z gradientu sprawia, że już na podstawie jednego punktu można określić kierunek, w którym należy poszukiwać rozwiązania.

W toku badań wdrożeniowych pod uwagę zostały rozpatrzone trzy metody gradientowe:

- Metoda największego spadku – ze względu na swoją małą złożoność obliczeniową;
- Nieliniowa metoda najmniejszych kwadratów (*Nonlinear Least Squares*) – ze względu na możliwość uwzględnienia niedokładności pomiarów;
- Nieliniowa metoda całkowitych najmniejszych kwadratów (*Nonlinear Total Least Squares*) – ze względu na możliwość uwzględnienia zarówno niedokładności pomiarów, jak i parametrów równania (należy do grupy określanej jako *errors-in-variables*).

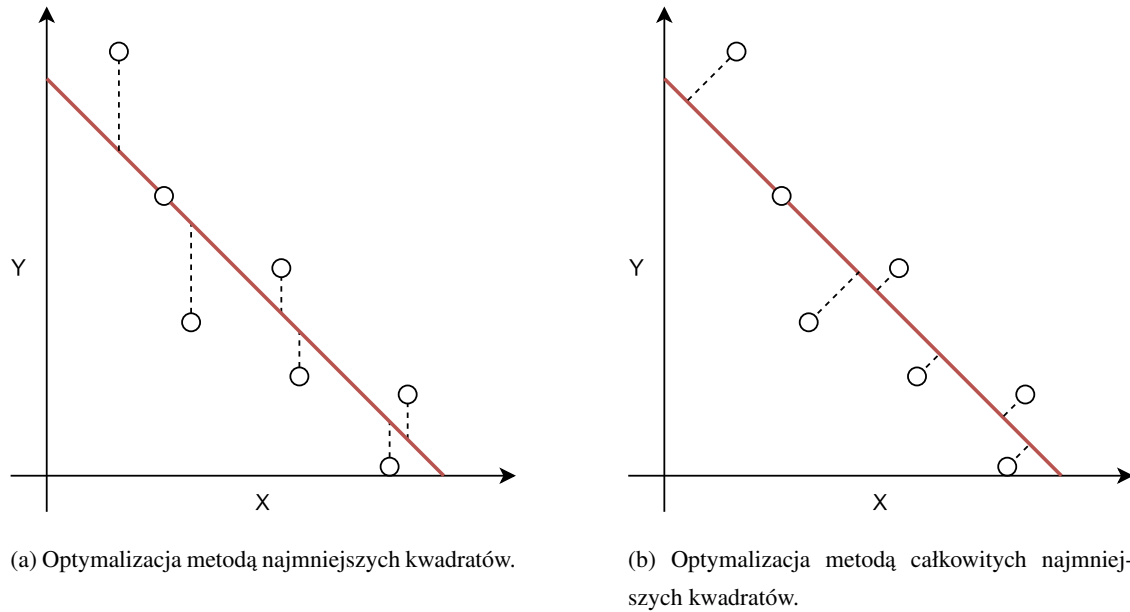
Przykład działania metody najmniejszych kwadratów oraz całkowitych najmniejszych kwadratów został zademonstrowany na rysunku 7.6. Jak można zauważyć, metoda całkowitych najmniejszych kwadratów uwzględnia niedokładności zarówno w osi X (parametr), jak i Y (pomiar). Metoda najmniejszych kwadratów zakłada, że parametr równania jest idealny, a pomiar może być obarczony błędem. Jak można zauważyć na przedstawionej ilustracji, w niektórych przypadkach te dwie metody mogą zwrócić ten sam wynik.

### 7.2.1 Metoda największego spadku

Metoda największego spadku jest jedną z najprostszych metod optymalizacji. Jej iteracje określone są przez kierunek przeciwny do gradientu funkcji celu i dane są wzorem [161]:

$$\mathbf{b}^{(n+1)} = \mathbf{b}^{(n)} - \eta^{(n)} \nabla \ell(\mathbf{b}^{(n)}), \quad n = 0, 1, 2, \dots, \quad (7.21)$$

gdzie  $\eta^{(n)}$  jest długością kroku. W zależności od wariantu  $\eta^{(n)}$  może przyjąć formę:



Rysunek 7.6: Porównanie metody najmniejszych kwadratów i całkowitych najmniejszych kwadratów. Punkty pomiarowe oznaczono okręgami. Czerwona linia oznacza dopasowany model, a przerywana minimalizowaną odległość. Inspirowane [164].

- stałej - w takim wypadku wartość  $\eta$  nie zmienia się pomiędzy iteracjami, a taka metoda jest określana mianem stałokrokowej;
- zmiennej - wyznaczonej poprzez poszukiwanie najmniejszej wartości funkcji celu na kierunku  $-\nabla \ell(\mathbf{b}^{(n)})$  za pomocą metod minimalizacji kierunkowej.

Ze względu na szum pomiarów radarowych w trakcie badań wdrożeniowych, rozważano jedynie metodę stałokrokową. Wybór ten został podyktowany obserwacją, że metody zmiennokrokowe zwiększały złożoność obliczeniową bez zauważalnej poprawy działania algorytmu.

### 7.2.2 Metoda nieliniowa najmniejszych kwadratów

Metoda najmniejszych kwadratów dopasowuje model tak, aby kwadrat błędu funkcji celu był jak najmniejszy. Funkcja celu dana jest wzorem [162]:

$$\ell(\mathbf{b}) = \frac{1}{2} \sum_{i=1}^M \|R_i(\mathbf{b})\|_2^2, \quad (7.22)$$

gdzie  $M$  to liczba obserwacji, a  $R_i$  oznacza  $i$ -te residuum pozostałe po dopasowaniu próbki do wybranego modelu.

W przypadku nieliniowej metody najmniejszych kwadratów należy zlinearyzować problem poprzez wyliczenie macierzy Jacobiego o rozmiarach  $M \times N$  [162]:

$$\mathbf{J} = \begin{bmatrix} \nabla \ell_1 \\ \nabla \ell_2 \\ \dots \\ \nabla \ell_n \end{bmatrix} = \begin{bmatrix} \frac{\partial \ell_1}{\partial b_1} & \dots & \frac{\partial \ell_1}{\partial b_n} \\ \frac{\partial \ell_2}{\partial b_1} & \dots & \frac{\partial \ell_2}{\partial b_n} \\ \dots & \dots & \dots \\ \frac{\partial \ell_m}{\partial b_1} & \dots & \frac{\partial \ell_m}{\partial b_n} \end{bmatrix}. \quad (7.23)$$

Kolejne iteracje parametrów można wyliczać na podstawie wzoru [162]:

$$\mathbf{b}^{(n+1)} = \mathbf{b}^{(n)} + \eta (\mathbf{J}^T \mathbf{J})^{-1} \mathbf{J}^T \mathbf{R}, \quad (7.24)$$

gdzie  $\mathbf{R}$  oznacza macierz residuów dla  $M$  próbek, a  $\eta$  jest arbitralnie dobranym krokiem.

### 7.2.3 Metoda nieliniowa całkowitych najmniejszych kwadratów

Algorytm całkowitych nieliniowych kwadratów wykorzystuje dekompozycje głównych składowych macierzy Jacobiego wzbogaconej przez macierz residuów, które można przedstawić jako [164]:

$$\mathbf{Z} = \begin{bmatrix} \mathbf{J} & \mathbf{R} \end{bmatrix}. \quad (7.25)$$

Dekompozycja głównych składowych macierzy  $\mathbf{Z}$ , jest dana wzorem [164]:

$$\mathbf{Z} = \begin{bmatrix} \mathbf{J} & \mathbf{R} \end{bmatrix} = \begin{bmatrix} \mathbf{U}_{svdJ} & \mathbf{U}_{svdR} \end{bmatrix} \begin{bmatrix} \boldsymbol{\Sigma}_{svdJ} & 0 \\ 0 & \boldsymbol{\Sigma}_{svdR} \end{bmatrix} \begin{bmatrix} \mathbf{V}_{svdJJ} & \mathbf{V}_{svdJR} \\ \mathbf{V}_{svdRJ} & \mathbf{V}_{svdRR} \end{bmatrix}. \quad (7.26)$$

Komponenty macierzy  $\mathbf{V}_{svd}$ , mogą zostać użyte do wyliczenia kroku parametrów w kierunku rozwiązania, poprzez zastosowanie wzoru:

$$\mathbf{b}^{(n+1)} = \mathbf{b}^{(n)} - \eta \mathbf{V}_{svdJR} \mathbf{V}_{svdRR}^{-1}. \quad (7.27)$$



## Rozdział 8

# Kalibracja i autokalibracja radarów samochodowych

Podczas gdy projekty czujników stają się bardziej skomplikowane i zwiększają swoje możliwości, niezbędne pozostają weryfikacja stanu sensora i informowanie o jego stanie pozostałych elementów systemu. Wydajność czujnika może zostać obniżona z powodu obiektu, który go zakrywa. W przypadku sensorów narożnych, niewłaściwie umieszczony lub pomalowany zderzak może utrudniać propagację fal radarowych lub załamać falę poza dopuszczalny zakres. Aby zredukować wpływ takich zjawisk producenci pojazdów są odpowiedzialni za uwzględnienie takich efektów w projektowaniu pojazdu i umieszczanie czujników tam, gdzie interferencja z osłoną jest minimalna. Podobne efekty mogą również wystąpić podczas codziennej eksploatacji pojazdu z powodu błota lub śniegu pokrywającego czujnik, co wymaga podejścia algorytmicznego do wykrywania blokady czujnika [10].

Systemy AD i ADAS składające się z wielu czujników wymagają przekształcenia detekcji na wspólny układ współrzędnych pojazdu (VCS), którego początek jest umieszczony na podwoziu pojazdu. Wymaga to precyzyjnych informacji o pozycji czujnika i kącie montażu. W przypadku niektórych sensorów dokładność pomiaru kąta horyzontalnego może osiągać wartości większe niż 1 stopień – co spełnia wymagania dotyczące dokładności radaru dla systemów AD i ADAS [165]—to dokładność kąta montażu nadal stanowi problem. Producenci pojazdów mogą podjąć środki zapobiegawcze w celu zwiększenia dokładności montażu, jednak nadal wymaga ona weryfikacji i dalszej korekty algorytmicznej. Problem nasila się, gdy radar jest wymieniany w warsztacie bez specjalistycznego sprzętu w wyniku kolizji lub awarii czujnika. W takim przypadku montaż wprowadzi błędy, które mogą być rzędu wielkości większe niż błędy algorytmów określania kąta radaru, co degradowe wydajność systemu. Niedokładności montażu kąтового (przekrzywienie radaru) mogą również wystąpić w trakcie standardowego cyklu życia pojazdu z powodu zużycia uchwyty montażowego lub drobnych kolizji, które mogłyby przesunąć czujnik lub zderzak przed nim. Normy regulacyjne i motoryzacyjne, takie jak ISO 26262, nakładają wymóg, aby czujniki dostarczały precyzyjnych pomiarów, a jeśli nie jest to możliwe, powinny ostrzegać system o usterce [166]. System wykorzystujący niewyrównany radar, który nie jest świadomy przekrzywienia, może działać nieprzewidywalnie (na przykład fałszywie wykrywając wiele nieistniejących obiektów). W praktyce podczas pracy w środowisku z wolno poruszającymi się obiektami i ograniczonym zasięgiem, takim jak parking, drobne niewyrównanie może nie

mieć istotnego wpływu na wydajność systemu. Ignorowanie przekrzywienia radaru jest jednak niemożliwe, ponieważ najbardziej niebezpieczne sytuacje dla systemu i jego użytkowników występują, gdy pojazd porusza się z dużą prędkością, a błąd obserwacji w takim wypadku sprawia, że nawet nieruchomy obiekt mógłby generować fałszywe hipotezy poruszających się w otoczeniu obiektów.

## 8.1 Fizyczne metody adiustacji

Wpływ niewłaściwego ustawienia radaru, oprócz błędów kątowych, które można łatwo skompensować algorytmicznie, wpływa na amplitudę istotnych detekcji, może wzmacniać amplitudę zakłóceń obecnych w otoczeniu (*clutter*) oraz znacznie zmniejszać zasięg detekcji radaru dla obiektów, które są trudne do wykrycia nawet przy idealnie ustawionym radarze. Te skutki można zniwelować jedynie poprzez korekcję kierunku wiązki anteny do optymalnej pozycji, co wymaga zastosowania obudowy sensora, która umożliwia korekcje zamontowanych radarów. Możliwe jest użycie zewnętrznych czujników do oszacowania kąta skrzywienia radaru w trybie online i zastosowanie silnika do ustawienia radarów, jak zaproponował Pinnock [167]. Taka metoda mogłaby fizycznie zminimalizować niewłaściwe ustawienie radaru, jednak może być zbyt kosztowna dla masowej produkcji. Inne metody proponowane przez wynalzców skupiają się na konstrukcji regulowanego uchwyty, który można skorygować pod określonym kątem po zmierzeniu lub oszacowaniu błędu orientacji [168]–[173]. Brak precyzyjnych siłowników znacznie obniża koszty, jednak wymaga dodatkowych komponentów mechanicznych, przez co szanse na wdrożenie takich rozwiązań w masowej produkcji są niewielkie.

## 8.2 Algorytmiczne metody kalibracji

Murad i inni opisują krótkie scenariusze, w których powinna być przeprowadzona kalibracja, w pracach [10], [165]. Zgodnie z tym opisem, algorytmy można sklasyfikować na podstawie przypadku użycia. Wymienione przypadki obejmują kalibrację na końcu linii produkcyjnej (*End-of-Line* – EOL), gdzie radary są kalibrowane na końcu procesu montażu pojazdu, aby zminimalizować niedokładności produkcyjne i kontrolować jakość. Warsztat samochodowy to drugi przypadek użycia, w którym przeszkolony technik może przeprowadzić proces kalibracji po wymianie radarów lub naprawie pojazdu. Trzeci wymieniony przypadek to kalibracja online, w której radar ciągle monitoruje i koryguje błędy ustawienia. Warto również wspomnieć o dwóch niewymienionych przypadkach użycia: kalibracji przeprowadzanej przez nieprzeszkolonego kierowcę, kierowanego prostymi instrukcjami (w przypadku podejrzenia, że radar mógł zostać przesunięty w wyniku wypadku, a warsztat samochodowy nie jest dostępny) oraz oszacowaniu kąta przekrzywienia w celu analizy offline (np. w celu ustalenia rzeczywistego kąta adiustacji w długim zbiorze danych).

Kalibracja będzie mieścić się w poniżej opisanych kategoriach:

- statyczna kalibracja, dla metod wymagających specjalistycznego zestawu kalibracyjnego, który może być podłączony do pojazdu w celu określenia kątów niewłaściwego ustawienia;

- kalibracja na torze, dla technik wymagających specyficznych celów drogowych lub kształtów drogi do oszacowania kąta, ale gdzie radar lub ECU pojazdu przeprowadza proces kalibracji samodzielnie podczas jazdy;
- kalibracja dynamiczna, dla algorytmów, które monitorują kąty niewłaściwego ustawienia w trakcie eksploatacji pojazdu bez nadzoru;
- kalibracja post-factum, dla metod oszacowania kąta niewłaściwego ustawienia na podstawie dużego zarejestrowanego zestawu danych z radaru po próbnym przejeździe.

Złożoność obliczeniowa, zużycie pamięci RAM i pamięci ROM jest jednym z parametrów, które decydują czy algorytmy kalibracyjne mogą być wykonywane przez procesor czujnika lub ECU pojazdu, co jest niezbędne w przypadku kalibracji na torze i kalibracji dynamicznej. Algorytmy różnią się również pod względem liczby radarów wymaganych do działania, oczekiwanym czasem wymaganym do dokładnego oszacowania kąta wychylenia oraz końcową dokładnością.

### 8.2.1 Statyczna kalibracja

Algorytmy w tej kategorii można podzielić na dwa przypadki użycia: kalibracja EOL — wykonywana na końcu procesu produkcji pojazdu oraz kalibracja serwisowa — stosowana w warsztacie samochodowym po wymianie radaru lub naprawie w pobliżu czujnika [174]. Oba te przypadki mają specyficzne wymagania. W przypadku EOL zazwyczaj jest ograniczona liczba linii montażowych, co umożliwia użycie droższego sprzętu kalibracyjnego. Jednak obszar, w którym przeprowadzana jest kalibracja, jest zazwyczaj ograniczony i współdzielony z innym sprzętem, co ogranicza możliwość korzystania z metod, które wymagają wielu celów lub celów na większej odległości. W miarę wzrostu produkcji pojazdów, producenci samochodów poszukują również sposobów, które zajmują jak najmniej czasu, aby zredukować ryzyko, że kalibracja stanie się wąskim gardłem produkcji. Z drugiej strony, kalibracja serwisowa powinna być możliwa do przeprowadzenia w niemal wszystkich certyfikowanych warsztatach. To oznacza, że metoda nie powinna polegać na drogich urządzeniach, ale może również skorzystać z faktu, że proces kalibracji może trwać nieco dłużej, bez znaczącego wpływu na efektywność.

Kąt horyzontalny radaru może być wyrównany przez umieszczenie co najmniej jednego celu w określonym miejscu względem radaru. Radar może następnie obliczyć odchylenie między zmierzonym a oczekiwanym kątem, aby określić niewłaściwe ustawienie azymutu [173], [175]. Metody oparte na tych zasadach nie wymagają drogiego sprzętu, co czyni je odpowiednimi do kalibracji warsztatowej. Jednym z mankamentów tej metody może być dokładność równa dokładności pomiaru azymutu w środowisku zwykle wypełnionym zakłóceniami i odblaskowymi powierzchniami, które mogą zakłócać pomiar. Poprawa dokładności może być osiągnięta poprzez zwiększenie liczby radarów obserwujących cele kalibracyjne i gdy to możliwe, ustawienie wielu celów kalibracyjnych w polu widzenia kilku radarów, a następnie znalezienie optymalnego rozwiązania dla wszystkich kątów niewłaściwego ustawienia radaru w ECU [176]. Zwiększona dokładność tego rozwiązania wiąże się jednak z ogromnym wzrostem wymagań dotyczących przestrzeni kalibracyjnej, co może nie być odpowiednie dla wszystkich linii montażowych, a nawet warsztatów. Można je przeprowa-

dzić tylko w systemie z wieloma radarami, nachodzącymi na siebie polami widzenia i celami w obszarach wspólnych dla tych pól widzenia.

Zwiększenie liczby celów pozwala na użycie algorytmów, które mogą nie wymagać pomiaru azymutu, a pozwalają oszacować pozycję i orientację radaru na podstawie pomiaru odległości, jak opisano w pierwszej części [177]. Użycie pomiarów odległości trzech celów radarowych do obliczenia wychylenia radaru może owocować większą dokładnością estymacji, w zależności od rozdzielczości zasięgu radaru i rozmieszczenia celów. Wielokrotne powtarzanie pomiarów celów kalibracyjnych w różnych pozycjach lub stosowanie wielu celów kalibracyjnych może zostać użyte do oszacowania zarówno błędu azymutu, jak i elewacji [178]–[180]. Zwiększająca się liczba celów może prowadzić do lepszej dokładności, jeśli rozkład błędu kąтового pomiaru radaru ma zerową średnią, co nie zawsze jest zagwarantowane, ponieważ między innymi odbicia wielodrożne mogą zakłócać estymację kąta, zwłaszcza dla elewacji. W przypadku wszystkich z rozważanych metod, zwiększanie liczby celów kalibracyjnych może nie być możliwe ze względu na ograniczenia przestrzeni roboczej.

Wspomniane metody, gdy są stosowane z pasywnymi celami, takimi jak reflektory sferyczne lub naróżne, są podatne na niedokładności spowodowane przez stacjonarne obiekty i powierzchnie w ich pobliżu, które mogą generować odbicia, zakłócające powracającą fazę sygnału. Aby uniknąć problemów spowodowanych przez ten efekt, korzystne może być użycie aktywnych celów, takich jak transponder opisany w [181], który może generować opóźnione odbicie ze zmienioną częstotliwością, symulując cel w odległości większej niż możliwa do uzyskania w warsztacie odległość od reflektorów statycznych oraz z unikalną w stosowanym otoczeniu prędkością generowanego celu kalibracyjnego. Takie urządzenie może poprawić wydajność kalibracji statycznej, generując cele dla zakresów i prędkości, które nie są zajęte przez inne obiekty, jednak znacząco zwiększa koszty stacji kalibracyjnej.

Dokładność możliwa do uzyskania w warunkach warsztatowych może nie być wystarczająca do oszacowania wysokiej jakości kątów przekrzywienia radaru. Symetryczna charakterystyka zysku większości anten samochodowych może dostarczyć informacji o kątach ustawienia na podstawie amplitudy fali radarowej transmitowanej do celu, która powinna być najwyższa, gdy cel znajduje się dokładnie w środku pola widzenia. Metody oszacowania niewłaściwego ustawienia na podstawie mocy sygnału w miejscu celu opisano w [182]–[184]. Przy starannie zaprojektowanych celach nie ma potrzeby korzystania z zewnętrznych urządzeń pomiarowych, ponieważ radar powinien być w stanie określić odbieraną moc odbicia. Metoda opisana w [185] opisuje kalibrację na podstawie dwóch celów umieszczonych symetrycznie nad i pod radarem, które generują taką samą amplitudę. W przypadkach, gdy radar jest właściwie zorientowany wertykalnie, amplituda fali odbitej od obu celów powinna być prawie identyczna. Radar będzie obserwować silniejsze odbicie od celu poniżej radaru, jeśli sensor jest niewłaściwie ustawiony w kierunku ziemi. Użycie celi kalibracyjnych, które zapewniają ostrą odpowiedź kątową, może jeszcze bardziej poprawić widoczność wzorców amplitudy. Jednym z nich jest płyta opisana w [174]. We wniosku patentowym zgłoszonym przez autora [11], kalibrację z metalową płytą dodatkowo udoskonalono, kompensując niedokładności kąta azymutu spowodowane przez boczne listki spektrum odbicia. Metody wyrównania oparte na mocy sygnału transmitowanego lub odbieranego mogą wiązać się z większymi kosztami sprzętu, ale mają znaczące zalety, ponieważ między

innymi mogą być używane do wyrównania radaru, nawet jeśli nie może on samodzielnie oszacować kąta elewacji celu.

Problem wyrównania można również traktować jako problem czysto mechaniczny, opisany w [186]. W takim przypadku można założyć, że wystarczy zmierzyć pozycję radaru za pomocą precyzyjnego sprzętu pomiarowego i albo fizycznie skorygować pozycję, albo skompensować kąt niewłaściwego ustawienia w oprogramowaniu sensora. Jak zauważa Abou-Jaoude w [174], ta metoda wymaga demontażu wszystkich części, które mogą zakrywać radar, i nie będzie ona w stanie wykryć ani skompensować niewłaściwego ustawienia spowodowanego przez załamanie fali podczas przejścia przez zderzak lub skrzywienie anteny.

### 8.2.2 Dynamiczna kalibracja

Dynamiczna kalibracja wymaga ciągłej, nienadzorowanej pracy algorytmu, która powinna być stosowana w celu utrzymania wysokiej dokładności detekcji radarowych przez cały okres eksploatacji sensora, aby zapewnić standardy bezpieczeństwa funkcjonalnego [166]. Dalsza część tej sekcji przedstawia przegląd dynamicznych algorytmów kalibracyjnych, sklasyfikowanych według potrzeby stosowania dodatkowych czujników lub niezależności od innych urządzeń pomiarowych.

#### **Dynamiczna kalibracja wspierana przez pomiary z czujników**

W [187] Preston i Olmstead złożyli wniosek patentowy dotyczący metod kalibracji opartych na akcelerometrach 3D zamontowanych na radarach i ramie pojazdu, aby określić kąt niewłaściwego ustawienia na podstawie różnicy między wektorami przyspieszenia. Prostsze implementacje kalibracji z użyciem czujników inercyjnych są opisane w [188] dla generycznych przednich czujników oraz w [189] dla przedniego radaru. W [190], Steinbuch i Schnabel opisują wynalazek zdolny do zmiany kierunku emisji anteny w celu skompensowania niewłaściwego ustawienia. Stosunkowo niskie koszty, małe rozmiary i dokładność nowoczesnych akcelerometrów mogą — przy zastosowaniu dodatkowej filtracji sygnału — zapewnić wysoką dokładność w oszacowaniu błędów kątowych montażu. Wadą tych metod opartych na akcelerometrach lub jednostkach IMU jest to, że wymagają one precyzyjnego montażu akcelerometrów na radarach oraz kalibracji przeprowadzanej na każdym sensorze w celu zapewnienia, że dostarczają one prawidłowe pomiary względem korpusu radaru. W przypadku montażu akcelerometru na radarze, proces ten mógłby być przeprowadzony jako część produkcji radaru. Czujnik przyspieszenia zamontowany na ramie pojazdu wciąż jednak musiałby być kalibrowany podczas montażu pojazdu, co mogłoby zwiększyć koszty produkcji.

#### **Dynamiczna kalibracja oparta na pomiarach radarowych**

Dotychczas opisane metody wykorzystują zewnętrzne czujniki, sprzęt i informacje o drodze, możliwe jest również oszacowanie kąta niewłaściwego ustawienia sensora wyłącznie na podstawie pomiarów radarowych. W zależności od konstrukcji radaru, niektóre pomiary mogą być dokładniejsze od innych. Te różnice między typami radarów wymagają starannego doboru metod używanych do kalibracji.

W przypadkach, gdy radar nie jest w stanie określić kąta elewacji obiektów lub dokładność tego kąta jest niewystarczająca, można zastosować metodę opisaną w [191]. Opiera się ona na opóźnieniu amplitudy fali odbitej od ziemi. W sytuacji, gdy radar jest niewłaściwie ustawiony w kierunku ziemi, opóźnienie szczytu

powracającej fali jest krótsze. Na podstawie różnicy w opóźnieniu zaobserwowanym przez odpowiednio ustawiony sensor można oszacować kierunek niewłaściwego ustawienia. Choć metoda ta nie wymaga detekcji radarowych do działania, należy rozważyć, że precyzyjny pomiar opóźnienia może nie być dostępny w każdym radarze.

Inna grupa algorytmów wykorzystuje pomiary odległości i azymutu do obliczenia niewłaściwego ustawienia na podstawie zależności trygonometrycznych. W [192], Ameen i Ryan używają detekcji innych poruszających się pojazdów, obserwowanych w dwóch różnych momentach, do oszacowania niewłaściwego ustawienia. Metoda Kima, opisana w [193], wykorzystuje cel we wspólnym polu widzenia dwóch radarów i wymaga jedynie pomiarów odległości. Innym podejściem jest metoda przedstawiona w [194], która obserwuje nieruchomy cel i wykorzystuje jego pomiary odległości i azymutu zebrane w różnych momentach. W przypadku tej metody istotne jest, aby pomiary użyte do obliczeń były wykonane, gdy pojazd przebył istotną odległość. W przeciwnym razie, jeśli pomiary są wykonane blisko siebie, może być trudno znaleźć unikalne rozwiązanie równań trygonometrycznych. Algorytmy oparte na dwóch pomiarach radarowych wymagają obserwacji celu we wspólnym polu widzenia. Nakładające się pole widzenia może nie być wystarczająco szerokie, aby zapewnić takie obserwacje, szczególnie biorąc pod uwagę, że oba sensory powinny być w stanie dokładnie wskazać punkt na celu raportowany przez drugi radar. Jednym z powodów niedokładności algorytmów z tej grupy jest to, że obiekty w otoczeniu mają skomplikowaną geometrię i w zależności od perspektywy radaru odbijają fale radarowe w różnych miejscach. To powoduje, że wspólny cel może nie być dokładnie w tej samej lokalizacji, która przyczynia się do błędu estymacji.

Zamiast bezpośrednich pomiarów radarowych, które mogą nie być dokładne, można wykorzystać wyniki algorytmów śledzenia. W [195] trajektoria śledzonego obiektu jest porównywana z trajekcją pojazdu, a różnice między nimi są używane do oszacowania kąta wychylenia sensora. Inne podejście zostało zastosowane w [196], gdzie algorytm wykorzystuje stany śledzenia dwóch radarów obserwujących ten sam obiekt do określenia błędów kąta montażu sensora. Kąty przekrzywienia można obliczyć na podstawie różnicy między znanym wektorem prędkości pojazdu a postrzeganym ruchem oszacowanym na podstawie stacjonarnych celów otaczających radar. Takie metody są przedstawione w [197], [198], gdzie pomiary azymutu i prędkości radialnej z wielu detekcji radarowych są wykorzystywane do oszacowania wektora prędkości sensora. W [199], użyto dodatkowych informacji z żyroskopu do wspólnego wyrównania radaru i odometrii pojazdu. W [200], wektor prędkości celu jest obliczany dla obiektów we wspólnym polu widzenia dwóch radarów, a różnica między dwoma obserwowanymi wektorami prędkości jest wykorzystywana do oszacowania błędu orientacji sensora.

Kolejna grupa metod wykorzystuje prędkość Dopplera i pozycję detekcji. Metoda oszacowania macierzy kalibracyjnej eliminującej niedokładności w rozmieszczeniu detekcji jest opisana w [201]. Znalezienie kątów wychylenia radaru można wykonać minimalizując błędy w równaniu prędkości radialnej, z użyciem metod przedstawionych w [202] lub [203]. Wysokiej precyzji czujniki z pomiarami azymutu i elewacji umożliwiają użycie metody opisanej w [204] do oszacowania niewłaściwego ustawienia azymutu i elewacji z czynnikiem korekcyjnym dla mierzonej prędkości pojazdu. W trakcie prac wdrożeniowych nad tym doktoratem opracowana i opatentowana została metoda kalibracji [12], opisana w dalszej części. Pod warunkiem uzyskania wystarczającej liczby detekcji stacjonarnych, algorytmy z tej grupy mogą dostarczyć

dokładnego i natychmiastowego oszacowania błędu orientacji. W zależności od wybranej metody, algorytm może być kosztowny obliczeniowo i nieodpowiedni do przetwarzania na procesorach wbudowanych. Kolejnym problemem jest wrażliwość optymalizacji nieliniowych na niedokładności danych. Problemy mogą również wystąpić, gdy algorytm otrzyma detekcje o niskiej dokładności kątowej lub detekcje (odbicia) od wolno poruszających się obiektów zamiast obiektów stacjonarnych.

### 8.2.3 Kalibracja na torze

Algorytmy kalibracji na torze przypominają algorytmy kalibracji dynamicznej ze względu na to, że obie te grupy muszą być wykonywane na radarze lub ECU pojazdu. Wiele algorytmów kalibracji dynamicznej mogłoby zostać zmodyfikowanych tak, aby uwzględniały zdefiniowane wzorce środowiskowe w celu zapewnienia wyższej dokładności oszacowania w krótszym czasie. Na przykład łatwo byłoby rozpoznać kształty wykonane z reflektorów narożnych lub barier/celów, które gwarantują tworzenie prostych linii wzdłuż trajektorii pojazdu [205]. Metoda opisana w [206] opiera się na geometrii otaczających barier, które muszą tworzyć linię równoległą do powierzchni drogi, aby określić wertykalny błąd orientacji sensora. Chociaż autorzy twierdzą, że metoda może działać bez nadzoru, kryteria wyboru danych wejściowych nie zostały szczegółowo opisane. Prowadzi to do wniosku, że dla algorytmu mogą stanowić problem między innymi nachylone bariery, co czyni go odpowiednim tylko dla specyficznych dróg. Przy odpowiednim ustawieniu celu drogowego dokładność i czas potrzebny na dokładne oszacowanie kątów przekrzywienia radaru mogą być lepsze niż w przypadku kalibracji dynamicznej. W takich przypadkach problemem może być wymagane miejsce na zestaw kalibracyjny, przez co mogą być nieadekwatne do większości zastosowań.

### 8.2.4 Kalibracja post-factum

Niektóre metody kalibracji wymagają złożonych obliczeń, które są zbyt kosztowne obliczeniowo, aby mogły być wykonywane na wbudowanym procesorze, lub wymagają przechowywania pomiarów radarowych przez dłuższy czas. Chociaż nie nadają się do bycia częścią urządzeń radarowych lub sprzętu kalibracyjnego, mogą dostarczyć bardziej dokładne kąty kalibracji, które mogą być użyte jako wartości referencyjne do analizy danych i rozwoju.

Przykładem jest algorytm oparty na detekcjach zebranych ze stacjonarnych celów, który tworzy mapę siatki w globalnym systemie współrzędnych. Mapy siatki mogą zostać przeliczane, zakładając różne kąty montażu sensora. Dla każdego kąta oblicza się funkcję kosztu, aby ocenić rozmycie nieruchomych obiektów na wynikowej siatce. Właściwy kąt montażu zostaje znaleziony, gdy stacjonarne obiekty na mapie siatki są najbardziej wyraźne [177]. W innej metodzie, Suzuki i in. [207] używają próbkowania Monte Carlo łańcuchami Markowa do oszacowania kąta niewłaściwego ustawienia jako tabeli korekcyjnej dla detekcji w różnych kątach azymutu. Metody używane do dopasowywania trajektorii obiektów obserwowanych przez wiele radarów, które pierwotnie nie były zaprojektowane do użytku w motoryzacji, mogłyby zostać użyte do oszacowania niewłaściwego ustawienia w systemie, w którym radary mają nachodzące na siebie pola widzenia [208]–[210]. W miarę jak systemy ADAS stają się bardziej skomplikowane i wymagają wielu czujników różnych typów, kluczowe staje się wyrównanie danych radarowych z pomiarami z innych sensorów. Kalibracja i fuzja danych z radaru, lidar i kamery stereowizyjnej są przedstawione w [211].

### 8.3 Wpływ błędu kąta montażowego na systemy ADAS i AD


Opisane w sekcji 8.3 zjawiska bazują na cytowanej literaturze, jednak wkładem własnym autora jest przeprowadzona analiza w kontekście błędu orientacji radaru, która nie istnieje w literaturze. Wyprowadzenia wzorów są wkładem własnym autora, ze szczególnym uwzględnieniem sekcji 8.3.5 w której za pomocą równań zespolonych wyprowadzono spodziewany błąd w estymacji zwrotu wektora prędkości celu w zależności od błędu kąтового orientacji radaru.

#### 8.3.1 Całkowite lub częściowe przysłonięcie czujnika

W przypadkach, gdy radar jest przekrzywiony pionowo w taki sposób, że cała transmitowana moc radaru jest skierowana poniżej linii horyzontu, czujnik może zostać częściowo lub całkowicie oślepiiony. Radar jest częściowo oślepiiony, gdy przekrzywienie pionowe nadal pozwala na transmisję części fali bezpośrednio w kierunku celu (górne pole widzenia czujnika nadal obejmuje dolną część celów). Maksymalny zasięg bezpośredniej detekcji w takim przypadku można obliczyć w uproszczonej formie na podstawie zależności trygonometrycznych, co przedstawia wzór:


$$R_{max} = \min \left( h \cdot \operatorname{ctg} \left( -\frac{\beta_{FoV}}{2} + \beta_m \right), R_{FoV} \right), \beta_m > \frac{\beta_{FoV}}{2}, \quad (8.1)$$

gdzie  $R_{max}$  reprezentuje maksymalny zasięg bezpośredniej detekcji [m] (odległość od radaru),  $h$  oznacza wysokość zamontowania czujnika (pozycję montażu pionowego nad ziemią) [m],  $\beta_{FoV}$  oznacza pole widzenia radaru w pionie [°],  $\beta_m$  oznacza pionowe przekrzywienie [°],  $R_{FoV}$  reprezentuje maksymalny zasięg radaru [m]. Przedstawienie maksymalnego zasięgu detekcji na bezpośrednią ścieżkę optyczną dla różnych wychyleń radarów pokazano na rysunku 8.1. Widać, że powyżej pewnego pionowego niewyrównania, w zależności od pola widzenia czujnika, degradacja zasięgu staje się katastrofalna i spada do wartości mniejszych niż 20 m.



Rysunek 8.1: Maksymalna odległość bezpośredniej detekcji dla radaru na wysokości  $h = 0,5$  [m] i maksymalnym zasięgu  $R_{FoV} = 100$  [m].

Warto również zauważyć, że radar może być w stanie wykrywać obiekty na większych odległościach niż te podane w równaniu (8.1) za pomocą pośredniej ścieżki stworzonej przez odbicie fali od drogi. Takie detekcje będą miały niższe prawdopodobieństwo wystąpienia w wyniku odbicia od nawierzchni tylko części mocy. Ponadto, będą one generować nieprawidłowe pomiary wysokości i odległości obiektu. Przykład takiego scenariusza zilustrowano na Rysunku 8.2. Zjawisko to występuje z powodu wysokiego współczynnika odbicia większości miejskich nawierzchni dróg przy częstotliwościach pracy radarów motoryzacyjnych. Podjęto wiele prób modelowania refleksyjności drogi i ilości mocy odbieranej z odbicia od drogi; jednak różnorodność materiałów drogowych i warunków środowiskowych czyni to zadanie skomplikowanym. Louis Nagy w [212], opracował model zdolny do oszacowania amplitudy odbitej mocy dla dróg asfaltowych, brukowych i żwirowych. Warunki środowiskowe mają ogromny wpływ na refleksyjność i rozpraszanie dróg. Model, który może przewidywać refleksyjność asfaltu pokrytego lodem lub wodą, został opisany i eksperymentalnie potwierdzony w [213], jednak nie tylko rodzaj nawierzchni, ale także różnice w strukturze materiału mogą wpływać na powstałe odbicia fali radarowej, co pokazano w publikacji pomiarów przeprowadzonych przez Kurza i in. w [214].




Rysunek 8.2: Radar przekrzywiony wertykalnie w kierunku ziemi. Jasnoniebieski obszar pokazuje moc transmisji radaru odbitą od ziemi. Ciemnoniebieska linia pokazuje ścieżkę fali odbitej (ciągła) oraz postrzeganą ścieżkę fali z detekcją widzianą przez czujnik (przerywana). Czerwona przerywana linia pokazuje niewyrównaną detekcję postrzeganą przez system, który nie jest świadomy przekrzywienia.

Kiedy czujnik jest przekrzywiony w stronę nieba, cel może nie być widoczny dla radaru, ze względu na brak powierzchni, która jest w stanie dostarczyć odbicie. W takim wypadku obserwowany obiekt może zbliżać się do pojazdu, pozostając poza wertykalnym zakresem pola widzenia i w zależności od tego jak bardzo przekrzywiony jest sensor, obiekt może zostać dostrzeżony ze znacznym opóźnieniem. Zagadnienia te są związane z bezpośrednią widocznością celu, czyli istnieniem tzw. ścieżki optycznej, ale wykrywanie obiektów przez radar zależy również od mocy sygnału, która powraca do anten. Moc ta zależy od charakterystyk kierunkowych zysków anten nadawczych i odbiorczych oraz od RCS celu, a wpływ jakie ma na nią przekrzywienie poruszony jest w sekcji 8.3.2.

W przypadku radarów o możliwości pomiaru kąta elewacji należy również rozważyć inny przypadek. Radar przekrzywiony względem nieba, jak w sytuacji przedstawionej na rysunku 8.3, będzie obserwował obiekty wkraczające w jego pole widzenia jakby znajdowały się pod radarem. Może to spowodować nieprawidłowe założenie systemu, że samochód powinien bezpiecznie przejechać ponad obserwowanym obiektem

lub przeszkodą. Zagadnienie to jest związane z przesunięciem oszacowanej pozycji detekcji względem samochodu, które zostało opisane w sekcji 8.3.4.



Rysunek 8.3: Radar przekrzywiony wertykalnie w kierunku nieba. Jasnoniebieski obszar obrazuje moc transmisji radaru. Ciemnoniebieska linia oznacza ścieżkę fali radarowej powodującą detekcję. Czerwona przerywana linia pokazuje niewyrównaną detekcję postrzeganą przez system, który nie jest świadomy przekrzywienia.

Całkowite zablokowanie czujnika może wystąpić, gdy radar jest niewyrównany w kierunku nieprzezroczystego obiektu, który całkowicie zablokuje falę radarową, takiego jak element podwozia pojazdu, silnik itp.. Zarówno częściowe, jak i całkowite zablokowanie może znacznie zmniejszyć zakres obserwacji radaru i pogorszyć ich jakość do tego stopnia, że algorytmiczne oszacowanie kąta przekrzywienia na podstawie detekcji radarowych staje się niemożliwe. W takim przypadku degradacja odczytów czujnika powinna być wykrywana za pomocą specjalistycznego algorytmu wykrywania przysłonięcia, niezależnego od detekcji radarowych, jak wspomniano w [10]. Przysłonięcie pola widzenia, poważne błędy orientacji oraz degradacja pomiarów powinny być traktowane jako usterki czujnika i odpowiednio obsługiwane przez system w celu osiągnięcia zgodności z normą ISO 26262 [166].

### 8.3.2 Spadek maksymalnego zasięgu

Rzetelne oszacowanie wpływu błędu orientacji na amplitudę sygnału może być przeprowadzone tylko przy szczegółowych informacjach o czujniku. W tej podsekcji obliczenia i analizy zostały przeprowadzone na antenach podobnych do tych opisanych w [8]. Podobne kroki można by zastosować z innymi modelami czujników. Niektóre radary z węższymi zakresami wysokiego wzmocnienia anteny w elewacji, które zazwyczaj oferują większe możliwości zasięgu, będą jeszcze bardziej podatne na degradację zasięgu opisaną w tej podsekcji.

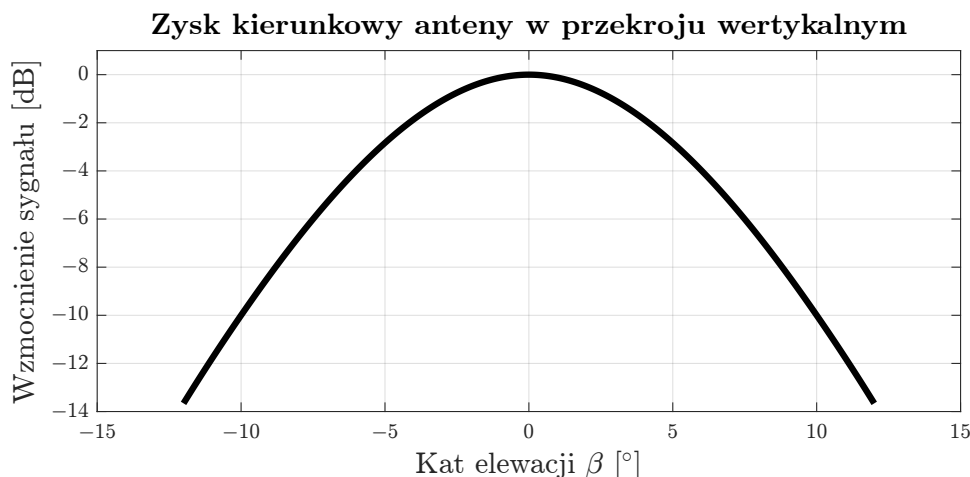
Radary muszą być małe, lekkie i mieć stosunkowo niską moc, aby można je było uznać za odpowiednie do użycia w pojazdach. Te wymagania stawiają wyzwania projektowe, które wymuszają kompromisy w niektórych specyfikacjach radarów. Jednym z najważniejszych parametrów radaru jest jego maksymalny zasięg detekcji. Jak opisano w [215], maksymalny zasięg radaru można rozumieć jako odległość, do której czujnik powinien wykrywać obiekty, do których został zaprojektowany. Opis ten może wydawać się zagmatwany,

ale jest bezpośrednio związany z mocą odbieraną ( $P_r$ ) opisaną przez [215]:

$$P_r = \frac{P_t G_t G_r \lambda^2 \sigma_{RCS}}{(4\pi)^3 r^4}. \quad (8.2)$$

Pierwsza część równania zawiera elementy bezpośrednio związane z radarem —  $P_t$  (moc transmisji [W]),  $G_t$  (wzmocnienie anteny transmisyjnej [ $\frac{1}{1}$ ]),  $G_r$  (wzmocnienie anteny odbiorczej [ $\frac{1}{1}$ ]), oraz  $\lambda$  (długość fali czujnika [m]). Druga część równania opisuje komponenty, które mogą się różnić w zależności od celu —  $\sigma_{RCS}$ , skuteczna powierzchnia odbicia [ $m^2$ ] (RCS), oraz  $r$ , odległość do celu [m]. W scenariuszach motoryzacyjnych, RCS celów może znacznie różnić się w zależności od typu celu i kąta ekspozycji. Dlatego niemożliwe jest zagwarantowanie udanej detekcji radaru od niektórych celów przy oczekiwanym maksymalnym zasięgu.

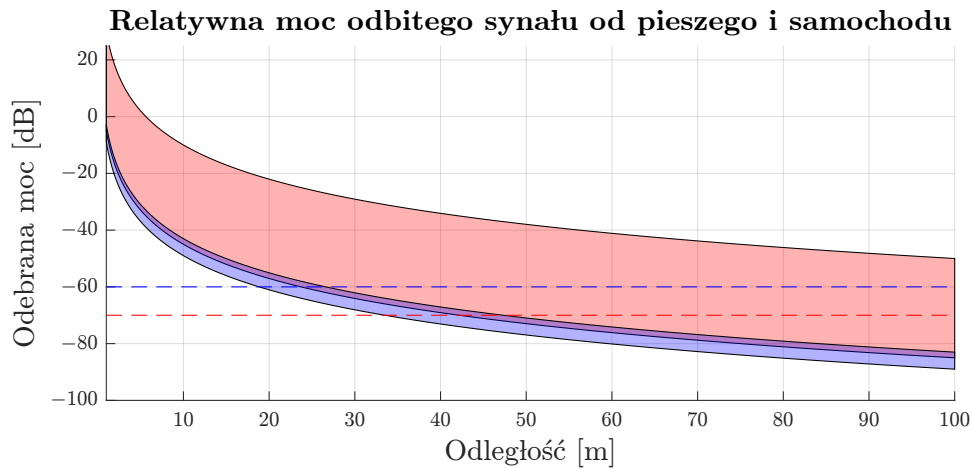
Większość radarów motoryzacyjnych oferuje szeroki zakres widzenia horyzontalnego. W związku z tym wpływ na zasięg z powodu przekrzywienia poziomego jest niewielki. Jednak stosunkowo wąska charakterystyka zysku w elewacji w kierunku pionowym — niezbędna do zminimalizowania niechcianych detekcji — może skutkować znacznym spadkiem wzmocnienia. Jak pokazano na Rysunku 8.4, 10-stopniowe przekrzywienie w elewacji, zastosowane do radaru z przybliżonymi parametrami anteny (zarówno transmisyjnej, jak i odbiorczej) z [8], skutkuje zmniejszeniem mocy sygnału o około  $-10$  [dB].



Rysunek 8.4: Stosunek pomiędzy transmitowaną a odbieraną mocą spowodowaną kierunkowym zyskiem anten w elewacji, przy założeniu, że anteny nadawcze i odbiorcze mają te same kąty montażu i pozycje oraz obserwują ten sam cel.

W tej analizie wykorzystano pomiary celów radarowych motoryzacyjnych autorstwa Geary’ego i in. z [216], aby zbadać dwie kategorie celów: pojazdy i pieszych. Korzystając z wartości RCS podanych w [216], moc odbita w stosunku do mocy transmitowanej została obliczona na podstawie równania (8.2). Wyniki, przedstawione jako przewidywany zasięg względnej mocy odbicia, zilustrowano na Rysunku 8.5.

Można założyć, że jeśli radar jest prawidłowo wyrównany, a jego nominalny zasięg wynosi około 80 [m], czułość odbiornika musi być na poziomie około  $-70$  [dB], aby wykryć pojazdy przy większości kątów ekspozycji. Przy założonej czułości bazowej czujnika i różnicy między odbieraną a transmitowaną mocą jako funkcji elewacji pokazanej na Rysunku 8.4, można oszacować czułość niewyrównanego czujnika, przesuwając punkt odniesienia, aby dopasować się do konkretnego niewyrównania elewacji. W przypadku czuj-



Rysunek 8.5: Odebrana moc odbicia od samochodu (czerwony obszar) i dorosłego pieszego (niebieski obszar). Przerywane linie przedstawiają minimalny poziom mocy wymagany do osiągnięcia detekcji dla prawidłowo zamontowanego radaru (czerwona linia przerywana) oraz radaru przekrzywionego wertykalnie o 10 stopni (niebieska linia przerywana).

nika przekrzywionego wertykalnie o 10 stopni i celu przed pojazdem lub wyrównanym czujnikiem i celem znajdującym się pod kątem 10 stopni w elewacji, minimalna moc musi być o 10 [dB] wyższa niż bazowa czułość, aby zrekompensować niższy zysk anteny transmisyjnej i odbiorczej.

Na podstawie takiej analizy można stwierdzić, że czujniki zaprojektowane do dostarczania detekcji radarowych dla większości klas pojazdów w zasięgu 80 metrów mogą wykrywać dorosłego mężczyznę w odległości 35 – 47 metrów w zależności od kąta ekspozycji. Pionowe niewyrównanie radaru o 10 stopni wpłynie na maksymalny zasięg czujnika dla wszystkich celów. Jednak najbardziej zauważalna zmiana dotyczy klasy pieszych, dla których maksymalny zasięg detekcji dorosłego mężczyzny może spaść do 18 – 27 metrów. Wpływ na mniejszych pieszych może być jeszcze bardziej znaczący. Aby zminimalizować skutki takich zjawisk, projektowanie systemów odpowiedzialnych za złożone funkcje, takie jak autonomiczna jazda, korzysta z wielu typów czujników, które obserwują otoczenie z zapewnieniem odporności na warunki środowiskowe i wykorzystując redundancje pomiarów, co zapewnia bezpieczeństwo innych użytkowników dróg. Jednak każdy projekt czujnika powinien dążyć do maksymalnej samodzielnej niezawodności, aby zapewnić jak najlepszą funkcjonalność systemu.

### 8.3.3 Rozróżnialność celów od szumu

Kolejnym istotnym czynnikiem, który należy wziąć pod uwagę podczas analizy wpływu przekrzywienia radaru na amplitudę detekcji, jest skuteczna powierzchnia odbicia obiektów zakłócających obraz otoczenia radaru. Odpowiednie cele muszą być rozróżnialne od otaczającego szumu, aby dostarczyć przydatnych informacji do systemu [217]. Jak opisano w [218], środowisko radaru jest wypełnione obiektami nieistotnymi dla większości zastosowań radarowych. Mogą to być skały, pnie drzew lub korzenie, nieregularne powierzchnie gleby i inne obiekty. W zależności od rodzaju terenu, szum może mieć różne poziomy amplitud, w zależności od jego charakterystyki. Podjęto pewne próby pomiaru szumu dla różnych rodzajów terenów i częstotliwości radarowych, a jedną z nich opisano w [219]. Wyniki tych pomiarów doprowadziły

do prób stworzenia metod matematycznych do oszacowania średniej amplitudy szumu krajobrazu, takich jak [220]. Przegląd różnych modeli szumu przedstawiono w [221]; praca ta, wśród wielu innych metod, przedstawia model szumu terenu dla niskich kątów natarcia fali radarowej, opracowany przez Georgia Institute of Technology [218]. Model ten dostarcza metody obliczania znormalizowanej refleksyjności szumu  $\sigma_{RCS}^0$ , która oznacza skuteczną powierzchnię odbicia szumu  $\sigma_{RCS}$  znormalizowaną w odniesieniu do  $A_c$  powierzchni oświetlonej przez impuls radarowy. Zależność ta jest opisana jako:

$$\sigma_{RCS} = \sigma_{RCS}^0 A_c. \quad (8.3)$$

Oświetloną przez impuls powierzchnię można obliczyć na podstawie współczynnika kształtu impulsu  $\alpha_c$ , rozdzielczości pomiaru odległości radaru  $\rho$ , odległości, w której spodziewane jest odbicie z nieistotnego obiektu –  $r$ , szerokości wiązki w azymucie  $\theta_{az}$  oraz kąta natarcia fali radarowej  $\phi_{gr}$ , używając wzoru:

$$A_c = \alpha_c \rho r \theta_{az} \sec \phi_{gr}. \quad (8.4)$$

Kąt natarcia fali radarowej jest obliczany jako

$$\phi_{gr} = \arcsin \left( \frac{h}{r} + \frac{h^2}{2R_e r} - \frac{r}{2R_e} \right), \quad (8.5)$$

gdzie  $h$  oznacza wysokość montażu radaru, a  $R_e$  oznacza promień Ziemi. Jednak w zastosowaniach motoryzacyjnych, gdzie zasięg radaru jest znacznie mniejszy niż 1 [km], równanie to można uprościć do:

$$\phi_{gr} = \arcsin \left( \frac{h}{r} \right). \quad (8.6)$$

Ostatecznie znormalizowana refleksyjność szumu może być obliczona jako:

$$\sigma_{RCS}^0 = A_g (\psi + C_g)^{B_g} \exp \left[ \frac{-D_g}{1 + \frac{0,1\sigma_h}{\lambda}} \right]. \quad (8.7)$$


$A_g$ ,  $B_g$ ,  $C_g$  i  $D_g$  są parametrami modelu dostępnymi w Tabeli 8.1,  $\psi$  to kąt depresji,  $\sigma_h$  to odchylenie standardowe nierówności powierzchni w [cm] a  $\lambda$  to długość fali radaru. Równania (8.3)–(8.5) oraz (8.7), Tabela 8.1, mogą być użyte do oszacowania skutecznej powierzchni odbicia szumu miejskiego jako funkcji odległości. Wyniki obliczeń przedstawiono na Rysunku 8.6.

Tabela 8.1: Wartości parametrów dla modelu szumu środowiska [218], [221].

Typ terenu	$A_g$				$B_g$	$C_g$	$D_g$
Częstotliwość [GHz]	15	9,5	5	3	∇	∇	∇
Ziemia, piasek, kamienie	0,05	0,025	0,0096	0,0045	0,83	0,0013	2,3
Trawa i pola	0,079	0,039	0,015	0,0071	1,5	0,012	0,0
Drzewa	0,019	0,003	0,0012	0,00054	0,64	0,002	0,0
Miejski	2,0	2,0	0,779	0,362	1,8	0,015	0,0

Dystrybucja amplitudy szumu otoczenia przy niskich kątach natarcia formuje dystrybucję Weibulla [218], [221], [222]. W zależności od typu otoczenia i częstotliwości, parametry tej dystrybucji mogą stworzyć długi ogon w kierunku obiektów o RCS dużo większym niż oczekiwana średnia. Szczegóły metodologii modelowania szumu otoczenia dla niskich kątów natarcia są zaprezentowane w [223]. Wspomniane modele zostały zaprojektowane dla fali w paśmie X (8 – 12 [GHz]), przez co ich przeniesienie na radary samochodowe operujące w zakresach częstotliwości 23 – 24 [GHz] [224]–[226] i 77 – 81 [GHz] [227]–[231] może nie dawać satysfakcjonujących wyników uzyskanych przybliżeń. Brak odpowiednich modeli dla tych typów radarów sugeruje, że powinien być to atrakcyjny kierunek dla przyszłych badań naukowych.

Rysunek 8.6 prezentuje oszacowaną średnią wartość RCS szumu miejskiego, która może zostać wykorzystana do porównania z oczekiwaną wartością RCS dorosłych pieszych z [216]. Oczekiwana wartość skutecznej powierzchni odbicia dla tych pieszych znajduje się w zakresie od  $-2$  do  $-9$  [dBsm]. Porównując te dwie wartości można zauważyć, że w przypadku przekrzywienia anteny radarowej w kierunku nawierzchni w taki sposób, że największy zysk kierunkowy anteny wskazuje nieistotne odbicia na drodze, a w takim wypadku charakterystyka anteny może być mniej korzystna dla obiektów na poziomie radaru, więc również pieszego na drodze. W wyniku tego zjawiska, odbicie wygenerowane przez niego może stać się nierozróżnialne spośród szumu i sklasyfikowane jako nieistotne, przez co system prawdopodobnie nie zostanie poinformowany o potencjalnym obiekcie na drodze.



Rysunek 8.6: Obliczone wartości średnie szumu miejskiego dla radarów o rozdzielczości pomiaru odległości 0,75 [m] oraz 0,25 [m]. Parametry użytego radaru: wysokość nad ziemią ( $h$ )—0,4 [m], szerokość wiązki w azymucie ( $\theta_{az}$ )— $90$  [°], współczynnik kształtu wiązki ( $\alpha_c$ )—1 oraz częstotliwość radaru - 15 [GHz].

### 8.3.4 Przemieszczenie detekcji i utrata pokrycia w obszarach zainteresowania

Przemieszczenie detekcji jest bezpośrednią konsekwencją przekrzywienia radaru. Zwracane azymuty i elewacje zawierają systematyczne błędy; tj. są one obciążone stałym przesunięciem we wszystkich pomiarach w stosunku do oczekiwanego wyniku pomiaru:

$$\begin{cases} \hat{\alpha}_n = \alpha_n + \alpha_m \\ \hat{\beta}_n = \beta_n + \beta_m \end{cases}, \quad (8.8)$$

gdzie  $\hat{\alpha}_n$  to skorygowany pomiar azymutu  $n$ -tej detekcji radaru,  $\alpha_n$  to pomiar azymutu  $n$ -tej detekcji radaru,  $\alpha_m$  to przekrzywienie azymutu,  $\hat{\beta}_n$  to skorygowany pomiar elewacji  $n$ -tej detekcji radaru, a  $\beta_n$  to pomiar elewacji  $n$ -tej detekcji radaru.

Przemieszczenie opisane w Równaniu (8.8) w trójwymiarowych współrzędnych kartezjańskich może przyjąć postać rotacji, która może być opisana za pomocą macierzy:

$$\begin{bmatrix} \hat{x}_n \\ \hat{y}_n \\ \hat{z}_n \end{bmatrix} = \mathbf{R}_z \mathbf{R}_y \mathbf{R}_x \begin{bmatrix} x_n \\ y_n \\ z_n \end{bmatrix}, \quad (8.9)$$

gdzie  $\hat{x}_n$  i  $x_n$  oznaczają odpowiednio skorygowaną i zmierzoną pozycję wzdłużną detekcji,  $\hat{y}_n$  i  $y_n$  oznaczają pozycję boczną detekcji, a  $\hat{z}_n$  and  $z_n$  oznaczają pozycję pionową detekcji.  $\mathbf{R}_x$ ,  $\mathbf{R}_y$  i  $\mathbf{R}_z$  to macierze rotacji wzdłuż odpowiednich osi.

W przypadku scenariusza drogowego przedstawionego na Rysunku 8.7, przekrzywienie radarów przednich może skutkować błędną klasyfikacją pasów ruchu, wzdłuż których poruszają się cele drogowe. Przy założeniu prostej drogi i celu punktowego znajdującego się dokładnie pośrodku pasa ruchu, minimalne niewyrównanie wystarczające do błędnej klasyfikacji celu na pasie ruchu może być wyrażone jako funkcja odległości od radaru:


$$\alpha_m^L = \arctg \left( \frac{W_R}{2r} \right). \quad (8.10)$$

gdzie  $\alpha_m^L$  oznaczanie wyrównanie azymutu wystarczające do błędnej klasyfikacji detekcji,  $W_R$  to szerokość pasa ruchu, a  $r$  to odległość między radarem a wykrytym obiektem (zasięg detekcji). Wynikową funkcję przedstawiono na Rysunku 8.8 zakładając, że szerokość pasa ruchu wynosi 3,75 [m].

Błędy montażu mogą również wpłynąć na obserwowalność otoczenia w obszarach szczególnego zainteresowania. W przypadku systemów zbudowanych na bazie sensorów narożnych, takich jak na rysunku 8.7, pojazd posiada martwe pole widzenia bezpośrednio przed samochodem. W uproszczeniu można je opisać jako trójkątny obszar pomiędzy radarami, z dwusieczną o długości, która zależy od pola widzenia oraz orientacji czujnika. Systemy aktywnego bezpieczeństwa często stosują kamery frontowe, które mają na celu pokrycie tego obszaru, ale sprawność funkcjonalności ADAS może spaść, jeśli ta strefa nadmiernie się zwiększy w wyniku błędów projektowych lub montażowych.

Zarówno frontowe jak i tylnie radary narożne mogą zostać wychylone od osi wzdłużnej pojazdu. Dla sensorów przednich oznacza to sytuację, w której obserwując to zjawisko z perspektywy ponad pojazdem, lewy odchyli się w kierunku przeciwnym do wskazówek zegara, a prawy zgodnie ze wskazówkami zegara. W takim przypadku martwe pole przed pojazdem pomiędzy nimi zwiększy się i w zależności od projektu systemu może wpłynąć na jego stabilność.

Długość dwusiecznej trójkąta, który tworzy martwe pole widzenia pomiędzy radarami, które można zaobserwować na rysunku 8.7, może zostać wyprowadzone na podstawie zależności trygonometrycznej, zakładając, że czujniki są zamontowane i przekrzywione symetrycznie do osi wzdłużnej pojazdu, jest dane



Rysunek 8.7: Potencjalny scenariusz błędnej klasyfikacji pasa ruchu i wizualizacja martwego pola przednich radarów z zaznaczonym polem widzenia czujników (niebieski obszar), krawędziami pola widzenia (przerwane linie) oraz osiami zwrotu sensora (czarna linia).

wzorem:

$$B_L = \operatorname{ctg} \left( \frac{\alpha_{FoV}}{2} - \alpha_b + \alpha_m \right) \cdot W_S. \quad (8.11)$$


Długość dwusiecznej w równaniu (8.11) jest oznaczona jako  $B_L$ ,  $\alpha_{FoV}$  oznacza horyzontalne pole widzenia radaru,  $\alpha_b$  jest bezwzględnym kątem montażu sensora,  $\alpha_m$  jest horyzontalnym błędem kątowym orientacji, a  $W_S$  oznacza odległość pomiędzy nimi. Wykres na rysunku 8.9 prezentuje wpływ przekrzywienia radarów na długość dwusiecznej martwego pola widzenia, dla różnych oczekiwanych kątów montażu oraz przy założeniu, że odległość pomiędzy radarami wynosi 1,8 [m], a horyzontalne pole widzenia wynosi 150 stopni.

### 8.3.5 Niedokładności wektora prędkości celu


Istotną cechą radarów motoryzacyjnych jest ich zdolność do określania kierunku i prędkości otaczających obiektów. W zależności od dostępnych zasobów obliczeniowych i architektury systemu, cecha ta może być realizowana na podstawie różnicy faz pomiędzy wieloma detekcjami tego samego obiektu [232] lub za pomocą fuzji informacji, gdy wiele radarów obejmuje ten sam obszar [233]. Prostszy podejściem do określania składowych wektora prędkości celu jest oparcie się na równaniu zasięgu radaru [234], wykorzystującym wielokrotne detekcje zmierzone z jednego celu, opisane jako:

$$\dot{r}_n = (T_x - V_x) \cos \alpha_{VCS_n} + (T_y - V_{\omega_y}) \sin \alpha_{VCS_n}, \quad (8.12)$$

gdzie  $T_x$  i  $T_y$  to składowe prędkości celu w systemie współrzędnych pojazdu,  $V_x$  i  $V_{\omega_y}$  to składowe prędkości pojazdu hosta w osiach wzdłużnej i poprzecznej, odpowiednio,  $\alpha_{VCS_n}$  to kąt, pod jakim obserwowana jest  $n$ -ta detekcja w systemie współrzędnych pojazdu (kąt równy 0 wskazuje w tym samym kierunku co oś wzdłużna pojazdu hosta, która jest również kierunkiem osi X układu współrzędnych pojazdu), a  $\dot{r}_n$  to prę-



Rysunek 8.8: Kąt przekrzywienia, który spowodowałby błędne przypisanie celu punktowego do niewłaściwego pasa ruchu w funkcji odległości.



Rysunek 8.9: Długość dwusiecznej obszaru martwego pola widzenia dla kątów montażu przednich radarów: 45 [°] (niebieski), 60 [°] (pomarańczowy), 65 [°] (żółty).

kość radialna (prędkość Dopplera, tj. składowa prędkości obserwowanego punktu rzutowana na kierunek w stronę lokalizacji montażu czujnika) dla  $n$ -tej detekcji.

Równanie (8.12) jest projekcją względnej prędkości celu na wektor kierunkowy obserwowanej detekcji. Inną reprezentacją równania (8.12), która lepiej odzwierciedla rozkład błędów, jest forma macierzowa lub równanie zespolone, które można opisać następującymi zależnościami:

$$\alpha_{VCS_n} = \alpha_n + \alpha_b + \alpha_m, \quad (8.13)$$

$$\bar{R} = (\bar{T} - \bar{V})\bar{D}_n^*, \quad (8.14)$$

$$\dot{r}_n = \Re\{\bar{R}\}, \quad (8.15)$$

$$\bar{D}_n^* = \cos \alpha_{nVCS} - \hat{i} \sin \alpha_{VCS_n}, \quad (8.16)$$

$$\bar{D}_n \cdot \bar{D}_n^* = 1. \quad (8.17)$$

Gdzie  $\overline{T}$  and  $\overline{V}$  to reprezentacje zespolone wektorów prędkości celu i prędkości pojazdu hosta, a  $\overline{D}_n^*$  to sprzężenie zespolonego wektora kierunkowego detekcji ( $\overline{D}_n$ ). Równanie (8.14), zatem reprezentuje rotację wektorów prędkości o kąt, który sprawia, że wektor kierunkowy detekcji znajduje się całkowicie w dziedzinie rzeczywistej, spełniając równanie (8.17), a  $\overline{R}$  reprezentuje względny wektor prędkości obrócony tak, aby spełniał równanie (8.15). Zespolona reprezentacja w równaniu (8.16) oraz fakt, że  $\alpha_{VCS_n}$  można rozłożyć według (8.13) są używane do wyprowadzenia:

$$\overline{D}_n^* = (\cos \alpha_n - \hat{i} \sin \alpha_n) \cdot (\cos \alpha_b - \hat{i} \sin \alpha_b) \cdot (\cos \alpha_m - \hat{i} \sin \alpha_m). \quad (8.18)$$

Rozłożone liczby zespolone w równaniu (8.18) są czysto rotacyjne (mają jednostkową wielkość). Zatem ich wpływ dotyczy jedynie fazy (kąta względnego wektora prędkości), co można udowodnić, porównując prawdziwy wektor prędkości względnej ( $\overline{R}_T$ ) z przekrzywionym wektorem prędkości względnej ( $\overline{R}_M$ ).

$$\begin{cases} \overline{R}_T = (\overline{T}_T - \overline{V})\overline{D}_n^* = \overline{X}_T\overline{D}_n^* \\ \overline{R}_M = (\overline{T}_M - \overline{V})\overline{D}_n^* e^{j\alpha_m} = \overline{X}_M\overline{D}_n^* e^{j\alpha_m} \\ \Re\{\overline{R}_T\} = \Re\{\overline{R}_M\} = \dot{r}_n \end{cases} \quad (8.19)$$

Uzyskanie takiego porównania wymaga rozwiązania układu równań (8.19). Aby uprościć zapis, wprowadzono wstępne – uzyskane przed rotacją przez  $\overline{D}_n^*$  –relatywne wektory prędkości ( $\overline{X}$ ). Następnie do rozwiązania układu, które wymaga wykorzystania części rzeczywistej liczby zespolonej, wykorzystana jest zależność pomiędzy liczbą zespoloną a jej sprzężeniem, co skutkuje wyprowadzeniem:

$$\begin{aligned} \frac{\overline{X}_M\overline{D}_n^* e^{j\alpha_m} + \overline{X}_M^*\overline{D}_n e^{-j\alpha_m}}{2} &= \frac{\overline{X}_T\overline{D}_n^* + \overline{X}_T^*\overline{D}_n}{2} \\ \frac{\overline{D}_n^* (\overline{X}_M e^{j\alpha_m} - \overline{X}_T) + \overline{D}_n (\overline{X}_M^* e^{-j\alpha_m} - \overline{X}_T^*)}{2} &= 0. \end{aligned} \quad (8.20)$$

Po usunięciu przypadków, w których równanie (8.20) ma nieskończenie wiele rozwiązań (np. gdy wielkość prędkości względnej jest równa zero), jedynym pozostałym rozwiązaniem jest:

$$\overline{X}_M = \overline{X}_T e^{-j\alpha_m}. \quad (8.21)$$

Zależność tę można następnie wykorzystać do obliczenia zależności pomiędzy prawdziwymi i niewyrównanymi wektorami  $\overline{R}_T$  i  $\overline{R}_M$ .

$$\frac{\overline{R}_T}{\overline{R}_M} = \frac{(\overline{T}_T - \overline{V})\overline{D}_n^*}{(\overline{T}_T - \overline{V})\overline{D}_n^* e^{-j\alpha_m}} = e^{j\alpha_m} \quad (8.22)$$

Wyprowadzone równanie (8.22) dostarcza wektora transformacji, który może być użyty do skorygowania wektora prędkości względnej obliczonego bez znajomości kąta przekrzywienia do prawdziwej wartości. Ważne jest, aby zauważyć, że  $\alpha_{VCS_n}$ , oznaczony w równaniu (8.13), jest prawdziwą wartością azymutu, dlatego wartość przekrzywioną można uzyskać, odejmując od niej  $\alpha_m$ . Przekrzywiony wektor  $\overline{D}_n^*$  można uzyskać poprzez mnożenie przez  $e^{j\alpha_m}$ , co usuwa komponent  $\alpha_m$  z równania (8.18).

$$\begin{cases} R_x = \frac{\dot{r}_1 \sin \alpha_{VCS2} - \dot{r}_2 \sin \alpha_{VCS1}}{\cos \alpha_{VCS1} \sin \alpha_{VCS2} - \cos \alpha_{VCS2} \sin \alpha_{VCS1}} \\ R_y = -\frac{\dot{r}_1 \cos \alpha_{VCS2} - \dot{r}_2 \cos \alpha_{VCS1}}{\cos \alpha_{VCS1} \sin \alpha_{VCS2} - \cos \alpha_{VCS2} \sin \alpha_{VCS1}} \end{cases} \quad (8.23)$$

$$\frac{R_{x_T} + \hat{i}R_{y_T}}{R_{x_M} + \hat{i}R_{y_M}} = \cos \alpha_m + \hat{i} \sin \alpha_m = e^{j\alpha_m} \quad (8.24)$$

Ta sama zależność może zostać udowodniona poprzez obliczenie składowych relatywnego wektora prędkości, używając informacji z dwóch detekcji radarowych, przy użyciu równania (8.23) i porównania ich dla prawdziwych oraz przekrzywionych wartości, za pomocą (8.24).

Różnica kierunków prędkości względnej może być wyprowadzona na podstawie równań (8.22) i (8.24), a zakładając Gaussowski rozkład błędu azymutu radaru, można oznaczyć ją jako:

$$E(\arg \bar{R}) = \mathcal{N}(-\alpha_m, \sigma_R^2). \quad (8.25)$$

Składnik losowy błędu kąta kierunku ( $\sigma_R$ ) jest spowodowany błędami pomiaru azymutu i może się zmieniać przez rozrzut detekcji i ich ilość. Można go zminimalizować poprzez zwiększenie rozdzielczości i separacji kątowej radaru, co zapewni dużą liczbę detekcji radarowych na pojedynczy obserwowany obiekt. Dalsze symulacje zakładają, że wpływy niedoskonałości detekcji radarowych są znikome (detekcje są idealne).

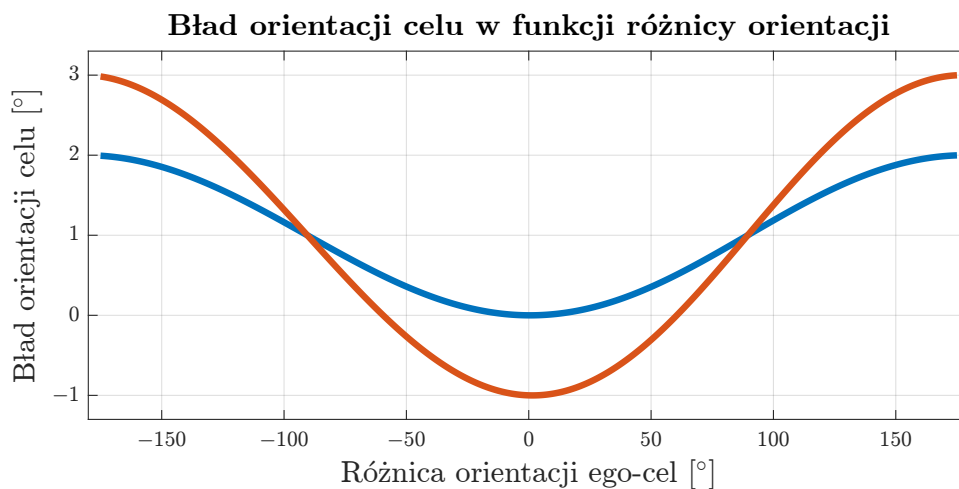
Aby znaleźć niedokładność wektora prędkości celu, równanie (8.14) można przekształcić w formę opisaną w następującym wyprowadzeniu:

$$\begin{aligned} \frac{\bar{R}_T}{\bar{R}_M} &= e^{j\alpha_m} \\ \bar{R}_M &= \bar{R}_T e^{-j\alpha_m} \\ \overline{TD_n^* D_n} &= \overline{RD_n} + \overline{VD_n^* D_n} \\ \bar{T}_M &= \overline{RD_n} e^{-j\alpha_m} + \bar{V}. \end{aligned} \quad (8.26)$$


Powstały wektor prędkości celu,  $\bar{T}_M$ , może zostać podzielony przez wektor prawdziwej prędkości celu  $\bar{T}_T$ , w następującym wyprowadzeniu:

$$\begin{aligned} \frac{\bar{T}_T}{\bar{T}_M} &= \frac{\overline{RD_n} + \bar{V}}{\overline{RD_n} e^{-j\alpha_m} + \bar{V}} \\ \frac{\bar{T}_M}{\bar{T}_T} &= \frac{\overline{RD_n} e^{-j\alpha_m} + \bar{V}}{\overline{RD_n} + \bar{V}} \\ \frac{\bar{T}_M}{\bar{T}_T} + \frac{\bar{V} e^{-j\alpha_m}}{\overline{RD_n} + \bar{V}} &= \frac{\overline{RD_n} e^{-j\alpha_m} + \bar{V}}{\overline{RD_n} + \bar{V}} + \frac{\bar{V} e^{-j\alpha_m}}{\overline{RD_n} + \bar{V}} \\ \frac{\bar{T}_M}{\bar{T}_T} + \frac{\bar{V} e^{-j\alpha_m}}{\overline{RD_n} + \bar{V}} &= \frac{(\overline{RD_n} + \bar{V}) e^{-j\alpha_m} + \bar{V}}{\overline{RD_n} + \bar{V}} \\ \frac{\bar{T}_M}{\bar{T}_T} &= e^{-j\alpha_m} - \frac{\bar{V} e^{-j\alpha_m}}{\overline{RD_n} + \bar{V}} + \frac{\bar{V}}{\overline{RD_n} + \bar{V}} \\ \frac{\bar{T}_M}{\bar{T}_T} &= \frac{1 + \frac{\|V\|}{\|T\|} e^{j(\angle V - \angle T)} (e^{j\alpha_m} - 1)}{e^{j\alpha_m}} \\ \frac{\bar{T}_T}{\bar{T}_M} &= \frac{e^{j\alpha_m}}{1 + \frac{\|V\|}{\|T\|} e^{j(\angle V - \angle T)} (e^{j\alpha_m} - 1)}. \end{aligned} \quad (8.27)$$

Równanie (8.27) pokazuje wpływ przekrzywienia radaru na prędkość celu, który wpływa zarówno na wielkość, jak i kąt wektora prędkości celu. W przypadkach, gdy pojazd ego jest nieruchomy lub porusza się znacznie wolniej niż cel, błąd kierunku i długości wektora będą bliskie zeru. W przypadku, gdy prędkość celu jest porównywalna z prędkością pojazdu ego, a kąt niewyrównania jest mniejszy niż 5 stopni, wpływ na kierunek można przybliżyć do składowej stałej równej  $\alpha_m$  oraz składowej sinusoidalnej przybliżonej do  $\frac{\|V\|}{\|T\|}\alpha_m$ , zależnej od różnicy pomiędzy kierunkiem pojazdu a kierunkiem celu. Wyniki symulacji potwierdzające takie zachowanie są pokazane na Rysunku 8.10. W przypadkach, gdy wielkość prędkości pojazdu ego jest znacznie większa niż prędkość celu lub kąt przekrzywienia jest znacznie większy niż 5 stopni, błąd kąta kierunku jest nieliniowy, jak przedstawiono na Rysunku 8.11, i nie może być intuicyjnie związany z  $\alpha_m$ .



Rysunek 8.10: Wpływ kąta przekrzywienia radaru wynoszącego 1 [°] na błąd kierunku celu dla prędkości celu równej prędkości pojazdu ego (niebieski) oraz dla prędkości pojazdu ego dwukrotnie większej niż prędkość celu (czerwony).



Rysunek 8.11: Wpływ kąta przekrzywienia radaru wynoszącego 7 [°] na błąd kierunku celu dla prędkości celu pięciokrotnie większej niż prędkość pojazdu ego (niebieski) oraz dla kąta przekrzywienia 1 [°] przy prędkości pojazdu ego dwudziestokrotnie większej niż prędkość celu.

Zmienny błąd kierunku spowodowany kątem przekrzywienia  $\alpha_m$  bez odpowiednich metod szacowania i kompensacji wywiera poważny, nieliniowy wpływ na szacowany kierunek i prędkość celu. Warto wspomnieć, że prawdopodobieństwo oszacowania kierunku celu można dalej weryfikować, na przykład porównując je z oszacowaną orientacją jak opisano w [235]–[238]. Jednak metody te, oprócz błędu estymacji, są również podatne na błędy kąta montażu sensora w ten sam sposób jak  $\bar{R}$ —z powodu nieznanego przesunięcia wpływającego na kąt azymutu, jak w równaniu (8.13).

### 8.3.6 Problemy z asocjacją danych

Jedną z najważniejszych funkcji nowoczesnych systemów aktywnego bezpieczeństwa jest fuzja informacji z wielu czujników i śledzenie otoczenia pojazdu. Odpowiednio zaprojektowana metoda, składająca się z różnych typów czujników, z różnymi zaletami i wadami, może w sposób odporny estymować otaczające środowisko i dostarczyć informacji o obiektach, które nie są możliwe do uzyskania za pomocą jednego czujnika. Przykładem fuzji wielu czujników jest system składający się z kamery, radaru i lidarów obserwujących to samo pole widzenia. W takim systemie radar dostarcza dokładnych informacji o prędkości względnej celu, lidar zapewnia kształt wysokiej rozdzielczości i precyzyjną pozycję, a kamera dostarcza dodatkowych informacji, które mogą poprawić detekcję małych i nierefleksyjnych elementów drogowych oraz pomóc w określeniu klasy celu (obiektu), takich jak sygnalizatory świetlne czy oznakowania pasów ruchu. Przykład fuzji kamery, radaru i lidarów wykorzystywanej do sterowania pojazdem opisano w [239], gdzie złożona architektura sieci neuronowej łączy dane z czujników, aby kontrolować kąt skrętu kierownicy, przyspieszenie i hamulce. Jak opisano w [240], autonomiczna jazda może być realizowana w podejściu end-to-end (za pomocą złożonej sieci neuronowej) lub w podejściu modułowym, w którym śledzenie danych i fuzja są wykonywane za pomocą algorytmów lub mniejszych sieci neuronowych o jasno określonych celach. Algorytmiczne podejście do fuzji danych z różnymi dostępnymi metodami jest szczegółowo opisane w [150].

Jednym z wyzwań metod fuzji danych działających w środowisku o nieznannej liczbie celów jest określenie, do którego śledzonego obiektu należy dana detekcja (asocjacja śladu/detekcji do istniejącego obiektu) lub czy powinna ona utworzyć zupełnie nową hipotezę obiektu (utworzenie nowego śladu lub podział istniejącego obiektu) [241]. Jedną z metod, która może asocjować detekcje z śledzonymi obiektami, jest metoda wspólnej probabilistycznej asocjacji danych (JPDA) i jej warianty opisane w [242]–[247]. Gdy danych nie można przypisać do żadnego istniejącego obiektu, muszą one zostać przechowywane jako hipoteza obiektu w celu dalszej asocjacji danych z innymi czujnikami lub następnego skanu radarowego. Aby odfiltrować obiekty, które mogą nie istnieć, z algorytmów śledzenia i fuzji danych dotyczących istotnych celów, można wdrożyć estymację pewności istnienia [248]–[252]. Intuicyjnie można wyjaśnić, że w każdym przypadku, gdy jakkolwiek czujnik wykryje obiekt o oczekiwanych stanach umożliwiających asocjację, prawdopodobieństwo istnienia wzrasta. Z drugiej strony, za każdym razem, gdy system nie może powiązać żadnej detekcji z obiektem, jego prawdopodobieństwo istnienia maleje. Nawet jeśli system może śledzić maksymalną liczbę obiektów, które mieszczą się w dopuszczalnych granicach obliczeniowych, cykl życia obiektu widocznego dla innych algorytmów rozpoczyna się, gdy jego prawdopodobieństwo istnienia przekracza określony próg i kończy się, gdy spada poniżej innego.

Bar-Shalom opisuje test służący do określenia asocjacji obiektów na podstawie kwadratowej odległości Mahalanobisa różnic stanów [150]. Wzór na oszacowaną różnicę stanów ( $\hat{\Delta}^{of}$ ) pomiędzy zmierzonym obiektem ( $\hat{x}^o$ ) a obiektem pochodzącym z fuzji ( $\hat{x}^f$ ) w indeksie czasowym  $k$  jest podany jako:

$$\hat{\Delta}^{of}(k) = \hat{x}^o(k) - \hat{x}^f(k). \quad (8.28)$$

Zakładając niezależność błędów, macierz kowariancji różnic stanów ( $P^{of}$ ) przyjmie postać:

$$P^{of}(k) = P^o(k) + P^f(k), \quad (8.29)$$

gdzie  $P^o$  oznacza kowariancję zmierzonego obiektu, a  $P^f$  oznacza kowariancję obiektu z fuzji.

Wyniki obliczeń z równań (8.28) i (8.29) mogą być użyte do obliczenia kwadratowej odległości Mahalanobisa i porównania jej z wcześniej ustalonym progiem  $D_\alpha$  aby określić, czy zmierzony obiekt może być powiązany z obiektem z fuzji według wzoru:

$$D \triangleq \hat{\Delta}^{of}(k)^T \left[ P^{of}(k) \right]^{-1} \hat{\Delta}^{of}(k) < D_\alpha. \quad (8.30)$$

W tej podsekcji, system oparty na obiekcie wygenerowanym za pomocą metody estymacji prędkości opisanej w sekcji 8.3.5, demonstruje zachowanie asocjacji danych. Załóżmy, że system odbiera idealny obiekt z fuzji i próbuje powiązać z nim oszacowany obiekt. Estymowany obiekt jest tworzony na podstawie 16 detekcji generowanych co 2 stopnie. Następnie na pomiar azymutu i prędkości zasięgu nałożony zostaje szum Gaussa. Algorytm wybiera trzy losowe detekcje i używa równania (8.23) do obliczenia oszacowanej prędkości i kierunku celu; następnie proces jest powtarzany 16 razy, a wyniki są zbierane. Mediana uzyskanych kątów kierunku jest używana jako ostateczne oszacowanie. Szacowany kąt kierunku jest porównywany z kątem kierunku obiektu z fuzji; jeśli różnica jest większa niż dwukrotność odchylenia standardowego kierunku, oszacowany obiekt nie będzie powiązany, a jeśli ta sama sytuacja wystąpi przez cztery kolejne skany, obiekt z fuzji powinien zostać podzielony i powinien zostać utworzony nowy ślad. Takie parametry zostały wybrane z założeniem, że jeśli błędy w oszacowaniach kierunku podążają za rozkładem normalnym, a radar wykonuje 20 pomiarów na sekundę, to nieprawidłowy podział śladu wystąpi rzadziej niż raz na 3 godziny. Symulacja generuje stosunkowo szerokie cele obejmujące 30 stopni w azymucie FoV, aby zminimalizować wpływ innych zjawisk na system. Zarówno wektory prędkości celu, jak i pojazdu ego poruszają się z stałą prędkością — cel porusza się na południe, a pojazd ego na północ. Ze względu na szerokość celu, przekrzywienie azymutu nie wpływa na asocjację w kontekście różnic w położeniu obiektu z fuzji i pomiaru, ponieważ wygenerowane detekcje przynajmniej częściowo będą się pokrywać z obiektem z fuzji. W tym scenariuszu głównym czynnikiem przyczyniającym się do nieprawidłowego podziału obiektu jest kierunek oszacowanego celu.


Rysunek 8.12 pokazuje rozkład błędów dla celu znajdującego się przed pojazdem. Dla prawidłowo wyrównanego radaru, odchylenie standardowe kąta kierunku celu z przodu wynosi poniżej 7 stopni, a średnia jest bliska zeru. W przypadkach, gdy cel znajduje się na innych azymutach, z powodu błędów azymutu i prędkości radialnej przechodzących przez model nieliniowy, rozkład błędów zmienia swój kształt, i nawet dla wyrównanych radarów nie jest to rozkład normalny, jak pokazano na Rysunku 8.13. Różnice w rozkładach błędów kierunku sugerują, że dla celów położonych na różnych kątach azymutu, może być korzystne

dobranie różnych progów asocjacji, które utrzymają prawdopodobieństwo asocjacji w tym samym zakresie, co dla celów z przodu pojazdu. Wyniki symulacji obejmują obliczenie oddzielnych progów dla celów położonych w różnych lokalizacjach.


Zaimplementowano trzy scenariusze dla celu położonego pod kątem  $-135$ ,  $0$  i  $135$  stopni względem przodu pojazdu, aby zwizualizować wpływ przekrzywienia radaru na niewłaściwe dzielenie obiektów. Dla każdego scenariusza wyznaczono odrębny próg w oparciu o rozkład błędów celu. Następnie dla kątów niedopasowania radaru od  $-15$  do  $15$  stopni w przyrostach co  $0,25$  stopnia, przeprowadzono obliczenia na skanach radarowych, korzystając z wyżej opisanych kroków. Prawdopodobieństwo podziału dla każdego z tych kroków przedstawiono na rysunku 8.14. Przesunięcia dla celów o kątach innych niż zero mogą się kompensować, gdy radar jest przekrzywiony pod odpowiednim kątem. Błędy kierunku celu mogą być kompensowane w bardziej złożonych algorytmach szacowania kierunku, jednak nie zniweluje to wpływu nieznanego niedopasowania radaru. W miarę wzrostu błędu orientacji radaru, liczba fałszywych podziałów śladów dramatycznie rośnie. W symulowanym środowisku, zamiast pojawiać się średnio raz na 3 godziny dla wyrównanego systemu, pojawi się raz na 45 minut z powodu 1-stopniowego niedopasowania, raz na cztery minuty dla 2-stopniowego niedopasowania i trzy razy na minutę dla 3-stopniowego niedopasowania. Przy 5-stopniowym niedopasowaniu system nie będzie w stanie pracować z powodu nadmiernej liczby nieistniejących obiektów raportowanych przez algorytm fuzji.

### 8.3.7 Lokalizacja i mapowanie

Błędy w ustawieniu anteny mogą również wpływać na algorytmy jednoczesnej lokalizacji i mapowania (SLAM). SLAM ma na celu ciągłą aktualizację mapy środowiska generowanej na podstawie odbić od stałych obiektów, które są przeliczane na globalny układ współrzędnych (GCS). Dla detekcji w GCS, niezbędne są precyzyjne pomiary dynamiki pojazdu oraz radaru. Jeśli radar jest źle ustawiony, konwersja detekcji



Rysunek 8.12: Funkcja gęstości prawdopodobieństwa (FGP) błędów kierunku celu dla wyrównanego i przekrzywionego radaru stworzona na podstawie symulacji. Parametry użyte w symulacji Monte Carlo: odchylenie standardowe  $-2$  [°], szerokość celu obserwowana przez radar —  $30$  [°],  $T - 10e^{j\pi}$  [m/s],  $V - 20e^{j0}$  [m/s], liczba realizacji pomiaru —  $10^8$ .




Rysunek 8.13: Funkcja gęstości prawdopodobieństwa (FGP) błędów kierunku celu dla wyrównanego i przekrzywionego radaru stworzona na podstawie symulacji. Użyte parametry takie jak w symulacji z rysunku 8.12, z wyjątkiem położenia centrum celu  $\alpha_{VCS} = -135$  [°].

z układu współrzędnych sensora (SCS) do GCS będzie obciążona systematycznym błędem [253]. Błąd ten, wprowadzony do pozycji stacjonarnego celu obserwowanego w odległości  $r$ , od pojazdu z orientacją względem GCS ( $\varphi$ ), jest opisany za pomocą:

$$\begin{cases} \Delta_x = r \cos(\alpha_b + \alpha_n + \alpha_m + \varphi) - r \cos(\alpha_b + \alpha_n + \phi) \\ \Delta_y = r \sin(\alpha_b + \alpha_n + \alpha_m + \varphi) - r \sin(\alpha_b + \alpha_n + \phi) \end{cases} \quad (8.31)$$

Odchylenie opisane w równaniu (8.31) pogorszy jakość znaków szczególnych, zebranych na mapie, rozmazując obraz środowiska.

Użycie SLAM lub Zintegrowanych Algorytmów Wykrywania i Komunikacji (ISAC) [254] do lokalizacji może prowadzić do błędów w orientacji z powodu nieprawidłowej orientacji anten. Szacowanie stanu pojazdu za pomocą jednego sensora będzie podlegać systematycznym błędom, które będą wynikały z esty-



Rysunek 8.14: Prawdopodobieństwo nieprawidłowego podziału obiektów w symulowanym scenariuszu dla celu obserwowanego pod kątami w układzie współrzędnych samochodu.

macji przeprowadzonej na przekrzywionej antenie. Systemy wykorzystujące wiele sensorów powinny być bardziej odporne na błędy ustawienia i poprawić zdolności lokalizacyjne, zakładając, że sensory są przekrzywione według losowego rozkładu o zerowej średniej.

Według [254], system radarowy ISAC składa się ze stacji bazowej, nadających i odbierających macierzy antenowych oraz sensorów z macierzami antenowymi zdolnymi zarówno do detekcji, jak i komunikacji. Ta konfiguracja wykorzystuje dużą ilość danych wejściowych do precyzyjnej lokalizacji, pozwalając na określenie względnej pozycji użytkownika z dużą dokładnością. Jednakże, jeśli antena stacji bazowej jest źle ustawiona, obliczenie pozycji użytkownika w GCS będzie obciążone tym samym błędem, jak opisano w równaniu (8.31). W związku z tym, gdy ISAC jest rozważany jako zastępstwo dla innych systemów lokalizacji użytkowników, to może być konieczne zastosowanie algorytmicznej korekcji ustawienia anten, tak aby osiągnąć wysoką rozdzielczość pozycjonowania w GCS.



## Rozdział 9

# Opracowane metody kalibracji radaru

Zadaniem realizowanym w trakcie prac wdrożeniowych było udoskonalenie stosowanych w firmie Aptiv metod kalibracji radaru samochodowego. W trakcie realizacji projektu potrzeby firmy oraz klienta, którym jest producent samochodów obejmowały:

- implementację nowego algorytmu statycznej kalibracji radaru, tak aby zapewnić metodę kalibracji w fabryce pojazdów oraz autoryzowanych warsztatach samochodowych;
- udoskonalenie stosowanego algorytmu dynamicznej kalibracji radaru, która pozwoliłaby spełnić oczekiwania klienta względem nowego projektu.

Wynikały one z potrzeby dostosowania istniejących metod do możliwości płynących z wprowadzanej nowej generacji narożnego radaru, umożliwiającej na pomiar elewacji.

Ze względu na reżim projektowy pierwotnie nacisk został położony na algorytm statycznej kalibracji, który musiał zapewnić estymację kąta horyzontalnego oraz wertykalnego przekrzywienia radaru, a także pomiar maksymalnej amplitudy sygnału podczas przejścia przez zderzak samochodowy w celu oceny parametrów przenikalności elektromagnetycznej stosowanego materiału oraz farby. Algorytm ten jest omówiony w sekcji 9.1.

W drugiej kolejności nacisk został położony na algorytm, który pozwoliłby na nienadzorowaną ocenę parametrów radaru i dynamiczną adiustację kątów radaru wraz z kalibracją pomiarów samochodu, czyli wyznaczeniem współczynnika korekty prędkości mierzonej na podstawie prędkości obrotowej kół. Prace te obejmowały również implementację procedury resetu wartości kalibracyjnych oraz przygotowanie zestawu szybkich konfiguracji, które pozwalałyby technikowi na uruchomienie automatycznej kalibracji na drodze o odpowiednich parametrach, przyspieszając całą procedurę. W trakcie prac postawiono tezę, że kalibracja radaru w jednej lub dwóch osiach jest niewystarczająca, ponieważ radar może zostać również skrecony, tj. obrócony dookoła osi wzdłużnej pola widzenia. Opis wdrożonego algorytmu przedstawiono w sekcji 9.2.

Na ostatnim etapie realizacji doktoratu, podjęto dalsze prace naukowo-badawcze, wykraczające poza zakres planowanego projektu wdrożeniowego i zaimplementowano dodatkowy algorytm, który jest w stanie dokonać trójosiowej adiustacji post-factum systemu złożonego z wielu radarów oraz wyznaczyć współczynnik prędkości samochodu, nawet jeśli stosowane radary nie dostarczają pomiarów elewacji. Pozwoliło to na zaimplementowanie algorytmu korzystającego z otwartego zbioru danych, a także jak wynika z uży-

skanych wyników udowodniło tezę, że trójosiowa adiustacja radaru jest w stanie poprawić jakość detekcji radarowych. Opis zaimplementowanego algorytmu przedstawiono w sekcji 9.3.

Jak można wywnioskować z dostarczonych opisów, algorytm kalibracji radaru ma za zadanie ocenę stanu zarówno samochodu ego, na którym się znajduje oraz potencjalnego wpływu elementów samochodu na pomiar. Można z tego wywnioskować, że jest on algorytmem fuzji, ponieważ wykorzystuje dane z różnych źródeł, które później muszą być odpowiednio połączone, aby uzyskać spójny opis parametrów radaru i samochodu. Dopiero po uzyskaniu dokładnej estymaty orientacji radaru oraz wektora prędkości samochodu można wyznaczyć na ich podstawie współczynniki korekcyjne i zaaplikować je do pomiarów radarowych. Z powodu ostatniego kroku, jakim jest korekcja wartości kątowych algorytmu kalibracji bywa on mylony z algorytmami wstępnego przetwarzania danych.

Architektura algorytmów kalibracji jest powiązana z architekturą systemów fuzji. W przypadku fuzji centralnej, która zbiera nieprzetworzone pomiary radarowe i wykorzystuje je do obliczeń na ECU istnieje możliwość implementacji algorytmów kalibracji tylko w obrębie jednostki obliczeniowej, co pozwala na wykorzystanie informacji jednocześnie ze wszystkich sensorów zwiększając znacząco jakość estymacji współczynnika korekcji prędkości. Dodatkową korzyścią z takiego rozwiązania jest większy zasób mocy obliczeniowej, ponieważ procesory sygnałowe, pomimo układów peryferyjnych umożliwiających sprzętową akcelerację obliczeń FFT, nie są projektowane pod kątem algorytmów wykorzystujących większe ilości RAM, ROM oraz wykonujących dużo operacji zmiennoprzecinkowych.

Implementacja rozwiązania, które wymaga wykorzystania ECU od tego samego producenta, jest jednak niekorzystna zarówno dla producenta radaru, jak i samochodów. W toku projektu może pojawić się potrzeba szybkiej implementacji rozwiązania, które jest w stanie działać zintegrowane z kompletnie innym producentem jednostek centralnych. Z tego względu radar, który jest w stanie samodzielnie dokonać kalibracji, wydaje się najbardziej uniwersalnym i korzystnym rozwiązaniem. Jeśli realia projektowe na to pozwalają, korzystne może być również opracowanie architektury w formie hybrydowej, która wykorzystywałaby wstępnie skalibrowane radary i udoskonalała ostateczne wartości kalibracyjne w obrębie algorytmów działających na jednostce centralnej.

Komponenty algorytmów kalibracji mogą różnić się w zależności od danych dostępnych na etapie przetwarzania. Poza detekcjami radarowymi oraz informacją o zmierzonej kinematyce pojazdu niektóre metody wykorzystują informację z trackera, czyli algorytmu śledzącego. Na jego podstawie można uzyskać dodatkowe, wiarygodne informacje o detekcjach tj. klasyfikacji obiektów poruszających się oraz identyfikacji detekcji z rozpoznawalnych elementów otoczenia takich jak bariery drogowe, a także wykluczenie detekcji, które są spowodowane przez wielokrotne odbicia fali radarowej spowodowane przez ściany lub bariery. Podstawowymi elementami tych algorytmów są:

- estymacja stanu pojazdu oraz sensora i wyliczania na ich podstawie wartości korekcyjnych;
- korekcja wartości za pomocą uzyskanych parametrów korekcyjnych.

Zaprojektowane algorytmy, z wyjątkiem opisanego w sekcji 9.3, są wdrożone jako część oprogramowania procesora sygnałowego działającego w obrębie radaru. Nałożyły to restrykcyjne ograniczenia pod względem wykorzystania pamięci oraz czasu wykonania pojedynczej iteracji algorytmu, co wykluczyło możliwości implementacji bardzo złożonych metod.

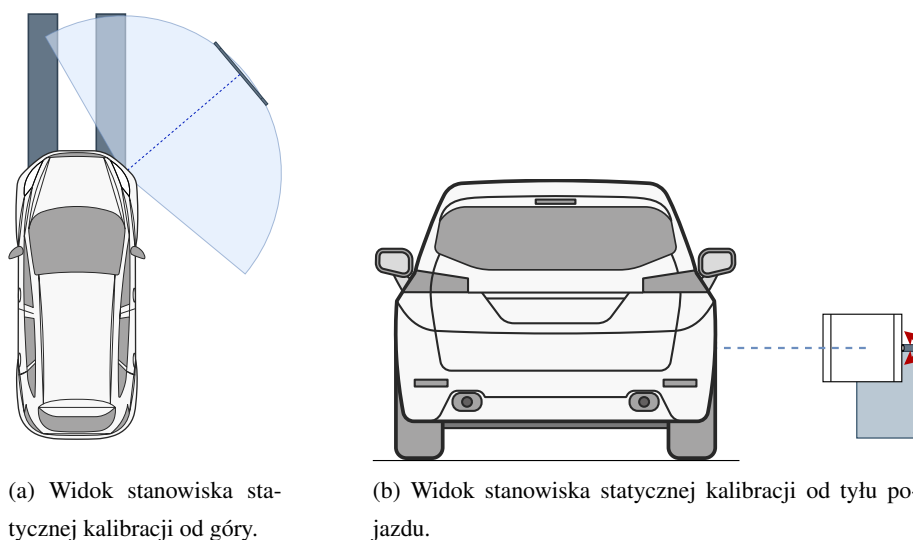
## 9.1 Kalibracja statyczna za pomocą wychylanej płyty

Kalibracja przeprowadzana w fabryce jest procesem, który generuje duże koszty po stronie producenta samochodów. Z tego względu procedura kalibracyjna przeprowadzana na linii montażowej musi być wykonywana w czasie, który jest na tyle krótki, że nie spowalnia linii produkcyjnej.

Środowisko, w którym musi działać kalibrowany radar, jest wyjątkowo niekorzystne, ze względu na mnogość metalowych powierzchni odbijających fale radarowe i wpływających negatywnie na estymację kąta nadejścia. Pomimo tych trudnień od algorytmu kalibracji oczekuje się wysokiej precyzji, a wymagania postawione w projekcie produkcyjnym wymagały oszacowania:

- kąta korekty pomiaru azymutu;
- kąta korekty pomiaru elewacji;
- oszacowania maksymalnej amplitudy odbieranej przez radar.


Aby uzyskać wymienione wartości kalibracyjne, postanowiono użyć znanej metody kalibracji orientacji radaru za pomocą metalowej płyty, zamontowanej na precyzyjnym serwomechanizmie, który pozwala na wychylanie płyty w kierunku podłoga i sufitu z zadaniem kątem. Z kolei samochód na linii produkcyjnej, jest precyzyjnie pozycjonowany, tak aby stalowa płyta znajdowała się bezpośrednio przed kalibrowanym radarem. Ilustracja pogładowa na stanowisko widoczna jest na rysunku 9.1.



Rysunek 9.1: Ilustracja przedstawiająca schemat stanowiska kalibracyjnego przedniego prawego sensora w fabryce. Samochód prowadzony po linii produkcyjnej jest pozycjonowany tak, aby bezpośrednio przed nim znajdowała się stalowa płyta, której wychylenie w elewacji może być precyzyjnie kontrolowane przez serwomechanizm.

Po dokładnym wypozycjonowaniu samochodu stacja kalibracyjna przesyła do radaru polecenie inicjalizacji procedury kalibracyjnej przedstawionej na rysunku 9.2. Następnie stalowa płyta lub lustro zamieszczone na serwomechanizmie wychyla się w kierunku podłoga o zadany kąt (w tym przypadku  $5^\circ$ ) i

przesyła do radaru informację o starcie procedury kalibracyjnej, która sprawia, że radar poszukuje odbicia w precyzyjnie określonej lokalizacji. W trakcie trwania procedury wyliczana jest średnia amplitudy i azymutu oraz ich wariancja za pomocą algorytmu Welforda, dla  $K$  skanów radarowych (w praktyce 10-50, w zależności od kalibracji, co sprawia, że czas zbierania pomiarów dla jednej pozycji może trwać od ułamka sekundy do kilku sekund).



Rysunek 9.2: Uproszczony schemat procesu kalibracyjnego dla parametrów:  $K$  - liczba detekcji pobieranych podczas jednego wychylenia płyty,  $N$  - liczba kroków w orientacji płyty,  $M$  - liczba losów do estymacji wariancji uzyskanych estymat.


Po zebraniu odpowiedniej liczby detekcji, radar wysyła do stacji kalibracyjnej informację, że przerywa zbieranie pomiarów i należy wychylić płytę do następnego zadanego kroku. Pomiaru są w ten sposób powtarzane dla  $N$  wychyleń płyty, a po ich zebraniu w pamięci następuje przejście do estymacji wartości maksymalnej amplitudy, kąta korekcji elewacji oraz azymutu. Na wyjściu z tej części algorytmu w pamięci znajduje się macierz  $N \times 3$ , która przedstawia kolejno: wartości  $N$  wychyleń w elewacji stalowej płyty,  $N$  średnich azymutów oraz  $N$  średnich amplitud pobranych dla tych wychyleń. Wartość  $N$  jest konfigurowalna, ale w praktyce nie stosowano więcej niż 11 pozycji.

Wyznaczenie błędu wertykalnego kąta montażowego jest w przypadku tej metody kalibracji uzyskiwane na podstawie estymacji kąta wychylenia stalowej płyty oraz pomiaru amplitudy z odbicia, które od niej pochodzi. Radary stosowane w samochodach posiadają znaczący spadek uzysku kierunkowego w ele-

wacji, ponieważ są projektowane do obserwacji szerokiego horyzontalnego pola widzenia, ale tylko na tym samym poziomie co samochód. W związku z tym można, sterując wychyleniem stalowej płyty, obserwować różnice amplitudy zwracanych detekcji. Amplituda ta, będzie miała największą wartość w przypadku, gdy fala radarowa uderza powierzchnie płyty pod kątem prostym i trafia z powrotem do radaru. Taka sytuacja jest zademonstrowana na rysunku 9.3, gdzie widać, że dla wychylenia płyty  $\beta_{fp}$  związek pomiędzy wychyleniem celu i radaru może zostać przedstawiony wzorem:

$$\beta_m = -\beta_{fp} \Leftrightarrow A_{fp}(\beta_{fp}) = \max_{\beta_{fp}} A_{fp}, \quad (9.1)$$

gdzie  $A_{fp}$  oznacza amplitudę fali radarowej odbitej od wychylanej płyty. Kąt wertykalnego misalignmentu jest przeciwny do wertykalnego wychylenia płyty. Zakładając, że kąty dodatnie oznaczają skierowanie obiektu w stronę podłoża, to znalezione maksimum amplitudy, dla płyty skierowanej w stronę podłoża, będzie oznaczać, że radar jest przekrzywiony wertykalnie w górę.




Rysunek 9.3: Schemat obrazujący działanie statycznej kalibracji za pomocą wychylanej płyty. Radar (z lewej) przekrzywiony w górę o kąt  $\beta_m$  obserwuje maksymalną amplitudę detekcji, gdy płyta (z prawej) jest wychylona o kąt  $\beta_{fp}$  w kierunku podłoża. Strzałki wskazują kąt zaczepiony w zerze i zwrócony w kierunku dodatnim dla pochylenia radaru (niebieski) i płyty (czerwony). Kąt dodatni oznacza pochylenie obiektu w kierunku podłoża.

Problem przedstawiony we wzorze (9.1) może wydawać się trywialny, jednak jego rozwiązanie w środowisku przemysłowym, pełnym metalowych obiektów, w reżimie czasowym oraz przy braku możliwości dokładnej synchronizacji staje się problematyczne. Wykonanie płynnego, powolnego ruchu stalowej płyty mogłoby dostarczyć najlepszych rezultatów, jednak problemem w tym wypadku była komunikacja ze stacją kalibracyjną, która podlegałaby znaczącym opóźnieniom. Z tego powodu stosowano opisane wcześniej  $N$  kroków stalowej płyty, którymi można było łatwo sterować, zapewniając, że jej pozycja jest zgodna z oczekiwaną.

Mała liczba kroków, wymuszona ograniczeniami czasowymi sprawia, że znacznym problemem może się okazać dyskretyzacja pomiaru, a także systematyczne błędy tych pomiarów, spowodowane istnieniem w środowisku metalowych obiektów. W trakcie prototypowania algorytmu napotkano na wiele sytuacji, w których pozostawiony w pobliżu celu kalibracyjnego niepożądany obiekt np. skrzynka z narzędziami zakrzywiała oczekiwany pomiar dla niektórych wychyleń stalowej płyty. W toku testów stało się jednak

jasne, że wykonywane pomiary, które miały wartości przybliżone do zilustrowanych na rysunku 9.4, są stabilne w obrębie jednej orientacji płyty, a więc mogą zostać uśrednione, a estymowana funkcja  $A_{fp}(\beta_{fp})$ , może być aproksymowana funkcją kwadratową.



Rysunek 9.4: Ilustracja prezentująca przykładowy przebieg pomiarów z wychylanej wertykalnie płyty. Kolory rozróżniają detekcje pochodzące z kolejnych orientacji celu.

W celu estymacji wiarygodności pomiaru zastosowano metodę samowsporną, polegającą na losowym wybieraniu podzbiorów trzech spośród wykonanych pomiarów, wykonaniu na ich podstawie aproksymacji wielomianu drugiego stopnia i wyliczaniu na uzyskanych parametrach funkcji kwadratowej pozycji maksimum, które odpowiadało przeciwności  $\beta_m$  jak w (9.1) oraz jego wariancji.

Aproksymacja wielomianu drugiego stopnia:

$$A_{fp}(\beta_{fp}) = b_1\beta_{fp}^2 + b_2\beta_{fp} + b_3, \quad (9.2)$$

została wykonana poprzez wykorzystanie metody najmniejszych kwadratów z wagami:

$$\mathbf{b} = (\mathbf{X}^T \mathbf{W} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W} \mathbf{A}_{fp}, \quad (9.3)$$

gdzie:

$$\mathbf{X} = \begin{bmatrix} \beta_{fp1}^2 & \beta_{fp1} & 1 \\ \beta_{fp2}^2 & \beta_{fp2} & 1 \\ \dots & \dots & \dots \\ \beta_{fpn}^2 & \beta_{fpn} & 1 \end{bmatrix}, \quad (9.4)$$

$$\mathbf{A}_{fp} = [A_{fp1} \quad A_{fp2} \quad \dots \quad A_{fpn}]^T, \quad (9.5)$$

$$\mathbf{W} = \left[ \begin{array}{cccc} \frac{1}{\sigma_{A_{fp_1}}^2} & & & \\ & \frac{1}{\sigma_{A_{fp_2}}^2} & & \\ & & \cdots & \\ & & & \frac{1}{\sigma_{A_{fp_n}}^2} \end{array} \right]^T, \quad (9.6)$$

a  $\sigma_{A_{fp_n}}^2$  oznacza wariancję pomiaru amplitudy w  $n$ -tej pozycji płyty. Zastosowane równanie posiada dodatkowe korzystne własności, jakimi jest symetria macierzy  $\mathbf{X}^T \mathbf{W} \mathbf{X}$ , dzięki której jej odwrotność jest również symetryczna. Pozwoliło to na redukcję liczby wymaganych operacji obliczeniowych przez pominięcie wyliczania powielonych wartości, redukując czas wykonania na procesorze wbudowanym we wdrożonej metodzie. Znalezienie wychylenia stalowej płyty, dla której amplituda zwróconej fali radarowej jest największa, oraz powiązanego z nim wertykalnego kąta przekrzywienia zostało uzyskane za pomocą własności równania kwadratowego:

$$\beta_m = - \left( -\frac{b_2}{2b_1} \right) = \frac{b_2}{2b_1}. \quad (9.7)$$

Na podstawie znalezionego ekstremum, dla poprawnie działającego procesu kalibracji, w którym amplituda sygnału posiada maksimum można obliczyć estymowaną wartość maksymalnej amplitudy wykorzystaną do sprawdzenia poprawności przejścia fali radarowej przez zderzak samochodowy:

$$\max A_{fp} = A_{fp} \left( -\frac{b_2}{2b_1} \right). \quad (9.8)$$

Kolejnym parametrem estymowanym w wyniku przedstawianego algorytmu jest horyzontalny kąt przekrzywienia radaru, który okazał się najbardziej problematyczny. W przypadku celu kalibracyjnego o oczekiwanej pozycji bezpośrednio przed radarem, można go wyznaczyć za pomocą:

$$\alpha_m = -\alpha_{fp}, \quad (9.9)$$

gdzie  $\alpha_{fp}$  oznacza kąt, pod którym obserwowane jest odbicie ze stalowej płyty.

Ze względu na charakterystykę anteny oraz celu, a także istnienie wielu ścieżek fali radarowej w otoczeniu, spowodowanych dużą liczbą metalowych obiektów, zebrane kąty nadejścia zawierały w sobie wiele próbek odstających, jak na rysunku 9.4. W wyniku kilkumiesięcznych badań stwierdzono, że żadna z modernizacji stanowiska kalibracyjnego, która mogłaby poprawić estymację kąta nadejścia nie jest możliwa do wykonania ze względu na wymagania klienta. Dodatkowa analiza zebranych pomiarów nie pozwoliła na znalezienie korelacji odstających pomiarów kąta azymutu z innymi parametrami detekcji. W związku z tym, postanowiono na wykorzystanie średniej odpornej do estymacji azymutu, a innowacje zgłoszono w patencie [11].

Algorytm średniej odpornej polega na iteracyjnym polepszaniu wyniku, w którym dokonuje się wyliczenia średniej i wariancji zbioru, a następnie odrzuca pomiary odstające o konfigurowaną wartość od średniej. W wypadku tego algorytmu zdecydowano się na dwie iteracje odrzucające pomiary oddalone od średniej o dwa odchylenia standardowe.


## 9.2 Dynamiczna trójosiowa adiustacja radaru z kompensacją prędkości

Stosowany algorytm statycznej kalibracji nie pozwala na poprawienie jednego z kluczowych wejść do systemu aktywnego bezpieczeństwa, jakim jest pomiar prędkości samochodu. Najczęściej przyjmuje się, że jest on obarczony stałym błędem, który wpływa proporcjonalnie na zmierzoną wartość. Wynika to z faktu, że jest on dostarczany na podstawie prędkości obrotowej kół samochodu, a na obwód koła może wpłynąć wiele czynników tj. zmiana opony, jej niedopompowanie lub zmiana temperatury.

Konieczność zaimplementowania dodatkowej metody poza statyczną kalibracją dyktuje również fakt, że od czasu wyjazdu samochodu z fabryki lub autoryzowanego warsztatu, radary mogą zostać poddane wielu czynnikom, które wpłyną na jakość ich pomiaru. Mogą to być kolizje, samodzielnie przeprowadzane naprawy lub powolna degradacja elementów montażowych, która może poskutkować obsunięciem się czujnika.

Aby upewnić się, że radar działa poprawnie podczas całego cyklu życia należy wykorzystać możliwości płynące z nienadzorowanych metod dynamicznej kalibracji, a także stosować algorytmy badające czy czujnik nie został zasłonięty oraz monitorować stan jego wyjść. Analiza literatury wykazała, że pomimo istnienia obiecujących algorytmów dynamicznej adiustacji, to wszystkie z nich są w stanie dokonać korekty jedynie horyzontalnego i wertykalnego kąta przekrzywienia radaru.

Radar może dokonać przesunięcia i przekrzywienia w trzech osiach, z tego względu modele pozwalające na korektę wyłącznie dwóch osi nie pozwalają na zupełną korektę błędów detekcji. Przykład takiej sytuacji widoczny jest na rysunku 9.5. Widać na nim, że nawet gdy skoryguje się horyzontalne i wertykalne przekrzywienie radaru, to jego skrócenie nadal ma znaczący wpływ na pozycję detekcji oddalonych od centrum pola widzenia. Co więcej można zauważyć, że ocena czy radar jest przekrzywiony na podstawie samego położenia detekcji lub ich kształtu wydaje się być bardzo trudna ze względu na złożoność otoczenia.



Rysunek 9.5: Ilustracja przedstawiająca wpływ przekrzywienia radaru na detekcje radarowe. Czerwone punkty przedstawiają detekcje radarowe naniesione na układ współrzędnych samochodu nieświadomego przekrzywienia radaru, zielone punkty oznaczają skorygowane detekcje, niebieskie strzałki oznaczają wektor korygujący detekcje.

W trakcie prac wdrożeniowych interesującą wydała się hipoteza, że estymacja trójosiowego błędu orientacji radaru, a następnie korekcja błędu pozwoli na zwiększenie precyzji pomiarów pozycji otaczających

obiektów. Aby wykonać taką operację i przedstawić detekcję pod kątem zgodnym z układem współrzędnych samochodu należy zastosować na pomiarach azymutu i elewacji radaru opracowane przez autora wzory:

$$\alpha_{VCS} = \alpha_b + \alpha_m + \alpha_n \cos \gamma_m - \beta_n \sin \gamma_m, \quad (9.10)$$

$$\beta_{VCS} = \alpha_b + \beta_m + \beta_n \cos \gamma_m + \alpha_n \sin \gamma_m, \quad (9.11)$$

gdzie  $\gamma_m$  oznacza skręcenie czujnika.

Skręcenie radaru przedstawione za pomocą wzorów (9.10) i (9.11) zostało zamodelowane poprzez zastosowanie macierzy rotacji na detekcji w sferycznym układzie współrzędnych sensora wokół punktu centralnego pola widzenia sensora, a następnie translację uzyskanych punktów o oczekiwany kąt montażu oraz błąd kątowy. Uzyskanie parametrów  $\alpha_m$ ,  $\beta_m$ ,  $\gamma_m$  jest zadaniem nietrywialnym, m.in. ze względu na korelację parametrów, które są związane ze sobą poprzez  $\gamma_m$ . Istnieje niewiele zjawisk, które są jednoznacznie z nimi związane i są wystarczająco dokładne, żeby pozwolić na ich estymację. Najbardziej wiarygodnym modelem, który sprawia, że można związać kąt detekcji z inną mierzoną przez radar wartością wydaje się równanie prędkości radialnej stacjonarnych detekcji:

$$\dot{r} = -(k_v V_x - V_{\omega_x}) \cos \alpha_{VCS} \cos \beta_{VCS} - V_{\omega_y} \sin \alpha_{VCS} \cos \beta_{VCS}, \quad (9.12)$$

gdzie  $k_v$  jest współczynnikiem korekcji prędkości samochodu, a  $V_x$ ,  $V_{\omega_x}$ ,  $V_{\omega_y}$  są pomiarami kinematyki pojazdu dostarczonymi przez system, lub wyprowadzonymi na podstawie dostarczanych pomiarów.

Aby wyznaczyć wartości parametrów  $k_v$ ,  $\alpha_m$ ,  $\beta_m$  i  $\gamma_m$  można posłużyć się metodami gradientowymi, które wymagają wyliczenia wartości ich pochodnych cząstkowych, które są dane kolejno wzorami:

$$\frac{\partial \dot{r}}{\partial k_v} = -V_x \cos \alpha_{VCS} \cos \beta_{VCS}, \quad (9.13)$$

$$\frac{\partial \dot{r}}{\partial \alpha_m} = -(V_{\omega_x} - V_x k_v) \sin \alpha_{VCS} \cos \beta_{VCS} - V_{\omega_y} \cos \alpha_{VCS} \cos \beta_{VCS}, \quad (9.14)$$

$$\frac{\partial \dot{r}}{\partial \beta_m} = -(V_{\omega_x} - V_x k_v) \cos \alpha_{VCS} \sin \beta_{VCS} + V_{\omega_y} \sin \alpha_{VCS} \sin \beta_{VCS}, \quad (9.15)$$

$$\begin{aligned} \frac{\partial \dot{r}}{\partial \gamma_m} = & V_x \alpha_n k_v (\cos \alpha_{VCS} \sin \beta_{VCS} \cos \gamma_m - \cos \beta_{VCS} \sin \alpha_{VCS} \sin \gamma_m) \dots \\ & - V_x \beta_n k_v (\cos \beta_{VCS} \sin \alpha_{VCS} \cos \gamma_m + \cos \alpha_{VCS} \sin \beta_{VCS} \sin \gamma_m) \dots \\ & + V_{\omega_x} \alpha_n (\cos \beta_{VCS} \sin \alpha_{VCS} \sin \gamma_m - \cos \alpha_{VCS} \sin \beta_{VCS} \cos \gamma_m) \dots \\ & + V_{\omega_x} \beta_n (\cos \beta_{VCS} \sin \alpha_{VCS} \cos \gamma_m + \cos \alpha_{VCS} \sin \beta_{VCS} \sin \gamma_m) \dots \\ & + V_{\omega_y} \alpha_n (\cos \alpha_{VCS} \cos \beta_{VCS} \sin \gamma_m + \sin \alpha_{VCS} \sin \beta_{VCS} \cos \gamma_m) \dots \\ & + V_{\omega_y} \beta_n (\cos \alpha_{VCS} \cos \beta_{VCS} \cos \gamma_m - \sin \alpha_{VCS} \sin \beta_{VCS} \sin \gamma_m) \dots \end{aligned} \quad (9.16)$$

Analizując przedstawione komponenty gradientu proponowanego modelu można zauważyć powtarzające się fragmenty, a ich istnienie może zostać wykorzystane do napisania optymalnego kodu na procesor sygnałowy. Jak można zauważyć, po prawidłowej optymalizacji, dla obliczenia gradientu jednej detekcji będzie konieczne obliczenie tylko sześciu operacji trygonometrycznych, jakimi są sinus i kosinus kątów:  $\alpha_{VCS}$ ,  $\beta_{VCS}$  i  $\gamma_m$ . Pomimo efektywnej implementacji na niektórych procesorach wykonanie tak dużej liczby

operacji zmiennoprzecinkowych, może okazać się niemożliwe w wymaganym reżimie czasowym. Aby zredukować liczbę obliczeń związanych z komponentem  $\gamma_m$ , można ograniczyć wykonanie algorytmu tylko do przypadków, kiedy samochód porusza się prosto i zredukować model do postaci:

$$\dot{r} = -k_v V_x \cos \alpha_{VCS} \cos \beta_{VCS}. \quad (9.17)$$

Gradient takiego modelu będzie składał się z komponentów:

$$\frac{\partial \dot{r}}{\partial k_v} = -V_x \cos \alpha_{VCS} \cos \beta_{VCS}, \quad (9.18)$$

$$\frac{\partial \dot{r}}{\partial \alpha_m} = V_x k_v \sin \alpha_{VCS} \cos \beta_{VCS}, \quad (9.19)$$

$$\frac{\partial \dot{r}}{\partial \beta_m} = V_x k_v \cos \alpha_{VCS} \sin \beta_{VCS}, \quad (9.20)$$

$$\begin{aligned} \frac{\partial \dot{r}}{\partial \gamma_m} = & V_x \alpha_n k_v (\cos \alpha_{VCS} \sin \beta_{VCS} \cos \gamma_m - \cos \beta_{VCS} \sin \alpha_{VCS} \sin \gamma_m) \dots \\ & - V_x \beta_n k_v (\cos \beta_{VCS} \sin \alpha_{VCS} \cos \gamma_m + \cos \alpha_{VCS} \sin \beta_{VCS} \sin \gamma_m). \end{aligned} \quad (9.21)$$

Proponowane ograniczenie działania do sytuacji, w której samochód jedzie prosto, nie będzie możliwe do zaimplementowania w przypadku każdego projektu. W zależności od miejsca użytkowania samochodu oraz stylu jazdy może się okazać, że takie obwarowanie sprawi, że algorytm będzie mógł działać kilkunastokrotnie rzadziej lub wcale. W przypadku rozpatrywania ograniczeń działania algorytmu należy zauważyć, że zaproponowane modele wymagają poruszającego się pojazdu do działania. W przeciwnym wypadku istnieje nieskończenie wiele rozwiązań tych równań. W trakcie prac wdrożeniowych przyjęto, że minimalna prędkość pojazdu, która powinna pozwolić na dokładne działanie algorytmu wynosi 5 [m/s]. Im większa prędkość pojazdu, tym detekcje ze stacjonarnego otoczenia dostarczają bogatszej informacji o prędkości radialnej, co poprawia dokładność algorytmu.

Uzyskane gradienty mogą zostać wykorzystane w metodzie największego spadku, zapisanej jako:

$$\mathbf{b}^{(n+1)} = \mathbf{b}^{(n)} + \eta \mathbf{J}^T \mathbf{R}_{\dot{r}}, \quad (9.22)$$

gdzie  $\mathbf{R}_{\dot{r}}$  oznacza residua prędkości radialnej. Parametr  $\eta$  może być zarówno skalarem, lub osobnym współczynnikiem dla każdego estymowanego parametru. W przypadku dobrania go jako skalar odwrotny do długości  $\mathbf{R}_{\dot{r}}$ , metoda największego spadku będzie podążać za średnim gradientem tych detekcji. W kontekście prac wdrożeniowych zadowalające rezultaty były osiągnięte dla parametru  $\eta$ , który był dany wektorem:

$$\boldsymbol{\eta} = \begin{bmatrix} \eta_{k_v} & \eta_{\alpha_m} & \eta_{\beta_m} & \eta_{\gamma_m} \end{bmatrix} = \begin{bmatrix} 10^{-6} & 10^{-3} & 10^{-2} & 10^{-2} \end{bmatrix}. \quad (9.23)$$

Odpowiednie dobranie  $\boldsymbol{\eta}$  sprawia, że zmiany parametru  $k_v$  nie wpływają destrukcyjnie na estymację  $\beta_m$  i  $\gamma_m$ , które mają znacznie mniejszy wpływ na wartość  $\dot{r}$ , co pozwala na zbiegnięcie się algorytmu do oczekiwanych wartości.

Gradienty mogą zostać również wykorzystane do nieliniowej metody najmniejszych kwadratów, która po dodaniu do niej parametru Marquardta ( $\lambda_m$ ) przyjmuje postać:

$$\mathbf{b}^{(n+1)} = \mathbf{b}^{(n)} + \eta (\mathbf{J}^T \mathbf{J} + \lambda_m \mathbf{I})^{-1} \mathbf{J} \mathbf{R}_{\dot{r}}. \quad (9.24)$$

Parametr Marquardta pozwala ustabilizować parametry, których zbieżność może zostać zaburzona przez niedokładności pomiaru oraz złe uwarunkowanie danych wejściowych, spowodowane np. zgrupowaniem detekcji w pobliżu siebie (w jednym obszarze pola widzenia). W przypadku nieliniowej metody najmniejszych kwadratów zastosowano  $\lambda_m = 10$  oraz:

$$\boldsymbol{\eta} = \begin{bmatrix} 10^{-3} & 10^{-2} & 10^{-2} & 10^{-2} \end{bmatrix}. \quad (9.25)$$

Implementacja nieliniowej metody całkowitych kwadratów, wymagała modyfikacji rozkładu wartości osobliwych do postaci:

$$\begin{bmatrix} \mathbf{U}_{svd\mathbf{J}} & \mathbf{U}_{svd\mathbf{R}_{\hat{r}}} \end{bmatrix}, \begin{bmatrix} \boldsymbol{\Sigma}_{svd\mathbf{J}} & 0 \\ 0 & \boldsymbol{\Sigma}_{svd\mathbf{R}_{\hat{r}}} \end{bmatrix}, \begin{bmatrix} \mathbf{V}_{svd\mathbf{J}\mathbf{J}} & \mathbf{V}_{svd\mathbf{J}\mathbf{R}_{\hat{r}}} \\ \mathbf{V}_{svd\mathbf{R}_{\hat{r}}\mathbf{J}} & \mathbf{V}_{svd\mathbf{R}_{\hat{r}}\mathbf{R}_{\hat{r}}} \end{bmatrix} = svd \left( \begin{bmatrix} \mathbf{J} & \eta\mathbf{R}_{\hat{r}} \end{bmatrix} \right), \quad (9.26)$$

w której został zastosowany skalarny parametr  $\eta = 2 \cdot 10^{-4}$ , pozwalający na ustabilizowanie optymalizacji. Iteracja nieliniowej metody całkowitych najmniejszych kwadratów może zostać zapisana jako:

$$\mathbf{b}^{(n+1)} = \mathbf{b}^{(n)} - \mathbf{V}_{svd\mathbf{J}\mathbf{R}_{\hat{r}}} / \mathbf{V}_{svd\mathbf{R}_{\hat{r}}\mathbf{R}_{\hat{r}}}. \quad (9.27)$$

Ostatnią zaimplementowaną metodą optymalizacji opracowanego modelu była bezgradientowa metoda sympleksu Nelder-Meada, w której zastosowano funkcję kosztów daną wzorem:

$$f(k_v, \alpha_m, \beta_m, \gamma_m) = \sum_{i=1}^{N_d} (\dot{r}_i + (k_v V_{x_i} - V_{\omega_{x_i}}) \cos \alpha_{VCS_i} \cos \beta_{VCS_i} + V_{\omega_{y_i}} \sin \alpha_{VCS_i} \cos \beta_{VCS_i})^2, \quad (9.28)$$

gdzie  $N_d$  oznacza liczbę detekcji użytych do wyznaczenia wartości funkcji kosztów. Zwiększenie parametru  $N_d$  pozwala na zmniejszenie chaotycznych kroków spowodowanych niedokładnościami pomiaru, poprzez uśrednienie ich błędów. Ze względu na wiążący się z tym zwiększony czas obliczeń, starano się wyznaczyć liczbę detekcji wystarczającą do wyliczenia funkcji kosztów w jednej iteracji. W wyniku testów wartość  $N_d = 16$  dała zadowalające rezultaty.

### 9.3 Trójosiowa kalibracja post-factum z kompensacją prędkości

Na końcowym etapie realizacji doktoratu stało się jasne, że opracowane metody mogą zostać wykorzystane na precyzyjnych radarach narożnych najnowszej generacji. Jednak ze względu na ochronę własności intelektualnej firmy oraz szczegółowych parametrów radaru niemożliwe jest opublikowanie zbioru danych testowych, które ujawniłyby informacje poufne konkurencyjnym przedsiębiorstwom. Niestety, pomimo poszukiwań nie udało się odnaleźć otwartego zbioru danych radarowych, który posiadałby pomiar elewacji detekcji i zawierał w sobie długie fragmenty ciągłej jazdy, pozwalające na testowanie algorytmów dynamicznej kalibracji. Dostępne zbiory danych, które spełniały wymaganie, co do długich fragmentów jazdy posiadały jedynie pomiary kąta horyzontalnego.

Ze względu na chęć udowodnienia tezy, że trójosiowa estymacja błędu kąta montażowego jest możliwa na otwartym zbiorze danych, poza projektem wdrożeniowym został opracowany algorytm, który działając na otwartym zbiorze danych, bez żadnych modyfikacji detekcji radarowych, będzie w stanie oszacować trójosiowe przekrzywienie radaru, pozwalające na redukcję błędu prędkości radialnej stacjonarnych detekcji.

Taka estymacja ze względu na brak informacji o kącie elewacji detekcji musi działać z pewnymi spodziewanymi założeniami:

- algorytm ma dostęp do pomiarów z wszystkich radarów, w obrębie samochodu;
- nieistniejący pomiar elewacji jest wypełniany losową wartością o rozkładzie równomiernym:

$$\beta_n \in [-0,02; 0,06] \text{ [rad]}, \quad (9.29)$$

przekesunięcie rozkładu równomiernego względem zera odzwierciedla przesunięcie pomiarów względem podłoża;

- przynajmniej jeden z zestawu radarów musi mieć mały błąd kąta elewacji (ale nie musi być wskazany algorytmowi);
- estymowana jest wartość bezwzględna kąta elewacji, co oznacza, że uzyskane wartości elewacji i skręcenia mogą mieć przeciwny znak do uzyskanych.

Proponowany algorytm powtarza w iteracji estymację współczynnika  $k_v$  kątów  $\alpha_m$ ,  $\beta_m$  i  $\gamma_m$  dla wszystkich radarów jednocześnie za pomocą metody całkowitych nieliniowych najmniejszych kwadratów.

Wartości początkowe parametrów zostają ustawione na:

$$\begin{bmatrix} k_v & \alpha_{m_k} & \beta_{m_k} & \gamma_{m_k} \end{bmatrix} = \begin{bmatrix} 1 & [\frac{1}{1}] & 0 & [^\circ] & 1,5 & [^\circ] & 0 & [^\circ] \end{bmatrix} \quad (9.30)$$

Funkcja kosztów w algorytmie dana jest wzorem:

$$f(k_v, \alpha_{m_1}, \beta_{m_1}, \gamma_{m_1}, \dots, \alpha_{m_{K_r}}, \beta_{m_{K_r}}, \gamma_{m_{K_r}}) = 0,1 \cdot k_v + \dots \\ \frac{1}{2} \sum_{k=1}^{K_r} (\hat{r}_k + (k_v V_{xk} - V_{\omega_{xk}}) \cos \alpha_{VCSk} \cos \beta_{VCSk} + V_{\omega_{y k}} \sin \alpha_{VCSk} \cos \beta_{VCSk})^2, \quad (9.31)$$

gdzie  $K_r$  oznacza liczbę radarów. Gradienty szukanych parametrów sprowadzają się do wartości jak we wzorach (9.14), (9.15) i (9.16). Pochodna czątkowa parametru  $k_v$ , ze względu na dodatkowy element w funkcji kosztów dana jest wzorem:

$$\frac{\partial f}{\partial k_v} = 0,1 - \sum_{k=1}^{K_r} V_x \cos \alpha_{VCSk} \cos \beta_{VCSk}, \quad (9.32)$$

Do obliczenia wartości kroków parametrów  $k_v$ ,  $\alpha_m$ ,  $\beta_m$  i  $\gamma_m$  użyto metody nieliniowych całkowitych najmniejszych kwadratów, działającej na zestawie 256 losowo wybranych detekcji z każdego z 4 radarów dostępnych w danych testowych. Macierz Jacobiego ma rozmiar  $256 \times 13$  i została wzbogacona o wyliczone residua jak we wzorze (9.26), używając  $\eta = 10^{-4}$ . Kroki algorytmu zostały uzyskane korzystając ze wzoru (9.27).

Przedstawiony algorytm jest wykonywany przez zadaną liczbę kroków. Ze względu na wyznaczenie metody poza środowiskiem samochodu można wykorzystać dużą liczbę iteracji oraz dużą liczbę detekcji w jednej iteracji. W metodzie nieliniowych całkowitych najmniejszych kwadratów, konieczne jest stosowanie znacznej liczby detekcji pomiarowych, a poprawa jej działania jest widoczna po przekroczeniu 128 detekcji na radar.

## Rozdział 10

### Dane

Gromadzenie danych radarowych w trakcie wdrażania nowego produktu jest problematyczne. We wczesnym okresie prototypowania czujnika trudno otrzymać poprawnie działający sprzęt, ze względu na małą liczbę wyprodukowanych egzemplarzy. Ponieważ na tym etapie możliwe są modyfikacje anteny oraz użytych komponentów, charakterystyka pomiaru i jego dokładności mogą się znacząco różnić pomiędzy iteracjami. Do podobnej sytuacji dochodziło w trakcie prac wdrożeniowych, a zmiany w wymaganiach klienta sprawiały, że reprezentatywne nagrania danych z radaru opóźniły się w czasie.

Na wstępnym etapie prac, kiedy dochodziło do zmian w obrębie czujnika oraz konieczne było korzystanie z prototypowego pojazdu testowego, który jeszcze nie posiadał stabilnego systemu, niezbędne było weryfikowanie uzyskanych danych. Poszukiwania potencjalnych błędów znacząco utrudniały pracę, były kosztowne czasowo, a ich pominięcie sprawiało, że nie można było stwierdzić, czy problemy z zachowaniem algorytmu kalibracji są spowodowane błędami implementacyjnymi, czy błędami w danych. Z tego powodu, jednym z badanych rozwiązań przedstawionym w sekcji 10.1, była automatyczna weryfikacja danych testowych przy użyciu sieci neuronowej. Opracowane rozwiązanie charakteryzowało się dużą prędkością działania, przy zachowaniu wyjątkowo lekkiej architektury, co pozwala sądzić, że dalszy rozwój tej metody mógłby zaowocować zastosowaniem projektowym.

Ochrona szczegółowych parametrów radaru, nad którymi pracowano we wstępnej fazie projektu, nie pozwala na wykorzystanie zebranych danych w rozprawie doktorskiej. W trakcie projektu doszło również do zmiany projektowej na urządzenie, które nie oferowało pomiarów elewacji. Pomimo że wstępny prototyp algorytmu dawał obiecujące wyniki należało dostosować dostępne pomiary, tak aby udowodnione zostały wstępne założenia doktoratu i postawiona teza. Z tego powodu w rozprawie zdecydowano na użycie dwóch rodzajów danych:

- dane z otwartego zbioru Radar Scenes, które mogą zostać wykorzystane bezpośrednio do algorytmu trójosiowej adiustacji post-factum opisanej w sekcji 9.3;
- symulacyjne dane, które powstały poprzez modyfikacje zbioru Radar Scenes, co pozwoliło na wygenerowanie syntetycznego pomiaru elewacji przy zachowaniu przestrzennego rozkładu detekcji odpowiadającego realnym pomiarom, który został opisany w sekcji 10.3.

Wykorzystane pomiary pozwalają na udowodnienie działania trójosiowej kalibracji radaru na niezmodyfikowanych danych rzeczywistych, a także na danych symulacyjnych, które są zbliżone do rzeczywistej dystrybucji w przestrzeni.

## 10.1 Automatyczna weryfikacja danych testowych

Sieci neuronowe zyskały popularność jako uniwersalna metoda rozwiązywania problemów zbyt złożonych dla tradycyjnych programów. Znajdują zastosowanie w wykrywaniu celów o niskim RCS, takich jak piesi [255], [256], rozpoznawaniu gestów [257], [258], detekcji obiektów [259], estymacji kąta [260] oraz klasyfikacji obiektów [261]. Większość współczesnych podejść wykorzystuje rozbudowane sieci z milionami parametrów, co może być nieuniknione w przypadku rozwiązywania złożonych zadań, ale znacząco zwiększa czas obliczeń. Z kolei walidacja ogromnych zbiorów danych wymaga olbrzymiej mocy obliczeniowej ze względu na rozmiar danych, często sięgający petabajtów. Aby zastosować sieć neuronową do przetworzenia takich zasobów, konieczne jest opracowanie minimalistycznej architektury, która pozwoli na przyspieszenie obliczeń oraz umożliwi walidację nawet na komputerach bez wydajnych układów GPU. Aby sprostać tym potrzebom zaproponowana została sieć neuronowa w dwóch wariantach o minimalistycznej liczbie parametrów, która została rozważana w zastosowaniu do dwóch potencjalnych zastosowań:

- estymacji prędkości liniowej oraz kątowej samochodu na podstawie detekcji radarowych;
- oceny aktualnego skanu radarowego pod kątem poprawności danych oraz klasyfikacji dostrzeżonego problemu.

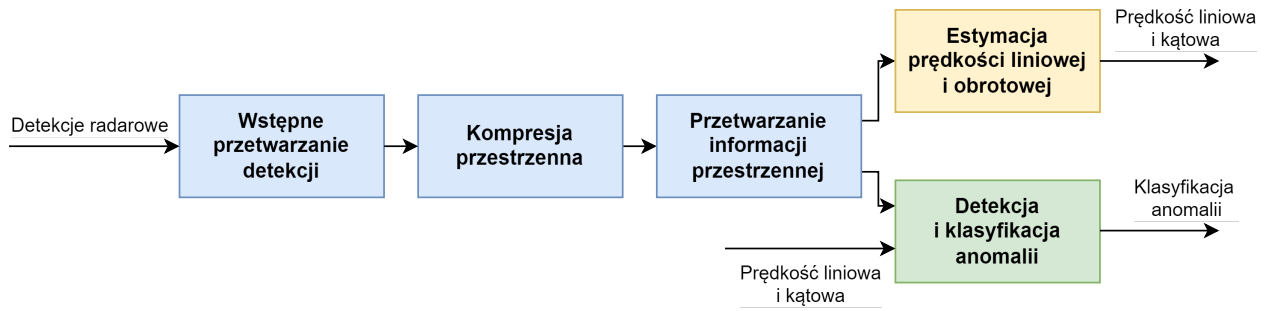
Pierwszy wariant sieci został zaimplementowany, żeby zweryfikować czy zaprojektowana architektura jest w stanie estymować prędkość liniową i obrotową samochodu. Jeśli proponowane rozwiązanie nie byłoby w stanie sprostać takiemu zadaniu, to szanse na to, że prawidłowo dokona oceny poprawności danych byłyby bardzo małe. Po potwierdzeniu, że sieć jest w stanie estymować stan otoczenia, można dokonać podmiany końcowego bloku sieci na taki, który pozwala na dostarczenie klasyfikacji aktualnego skanu radarowego w kontekście wystąpienia i rodzaju anomalii.

### 10.1.1 Architektura sieci walidacyjnej

Zaproponowano dwie sieci neuronowe bazujące na wspólnych elementach architektury we wstępnych blokach algorytmu. W zależności od zastosowania jako końcowy blok zostaje wybrany:

- blok estymacji prędkości liniowej i obrotowej - dla pierwszego wariantu sieci, który ma zweryfikować poprawność architektury;
- blok detekcji i klasyfikacji anomalii - dla docelowego wariantu sieci, który pozwala na klasyfikację potencjalnych problemów.

Schemat architektury został zademonstrowany na rysunku 10.1.



Rysunek 10.1: Schemat dwóch zaproponowanych sieci walidacyjnych. Wspólne elementy zostały przedstawione kolorem niebieskim, element użyty w przypadku sieci estymującej prędkość kolorem żółtym, a element użyty w przypadku sieci do klasyfikacji anomalii kolorem zielonym.

### Wejścia sieci neuronowej

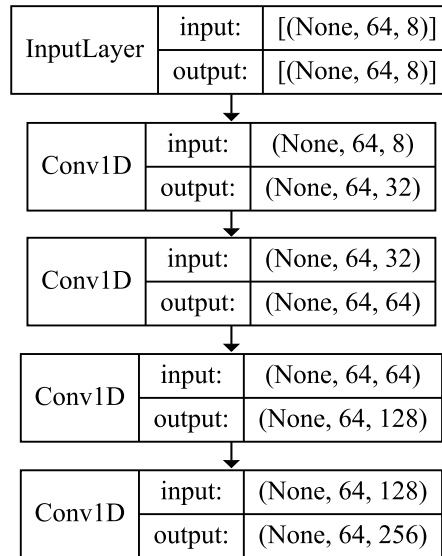
Wejście modelu zawiera maksymalnie 64 detekcje radarowe z ośmioma parametrami wejściowymi:

- kosinus zmierzonego kąta azymutu;
- sinus zmierzonego kąta azymutu;
- kosinus zmierzonego kąta elewacji;
- sinus zmierzonego kąta elewacji;
- odległość detekcji od radaru;
- prędkość radialna;
- odbita amplituda;
- stosunek sygnału do szumu.

Jeśli, w którymś momencie, radar zarejestrował mniej niż 64 detekcje, pozostałe pola macierzy danych wejściowych są uzupełniane zerami.

### Blok wstępnego przetwarzania detekcji


Pierwszym blokiem w zaproponowanej architekturze jest blok wstępnego przetwarzania detekcji. Został on stworzony w celu przetwarzania danych z detekcji i dostarczania informacji z każdej detekcji na temat wyglądu otaczającego środowiska. Składa się on ze splotów jednowymiarowych z jądrem o rozmiarze pojedynczej komórki oraz warstw aktywacyjnych typu leaky ReLU. Schemat blokowy przedstawiono na rysunku 10.2.



Rysunek 10.2: Schemat architektury bloku wstępnego przetwarzania detekcji w zaproponowanej walidacyjnej sieci neuronowej.

### Blok kompresji przestrzennej


Druga część architektury jest przedstawiona na rysunku 10.3 i odpowiada za kompresję informacji przestrzennych wykorzystując fakt, że każda detekcja dostarcza informacji o otoczeniu obserwowanym przez wiele detekcji, które może być traktowane jako jeden obiekt. Zatem można podjąć próbę takiego ułożenia warstw sieci, aby wymusić kompresję danych, sumując wszystkie wartości filtrów z detekcji w jedną wspólną przestrzeń. Wykorzystana reorganizacja komórek w warstwę o dwóch wymiarach z kanałami parametrów, zmusza sieć do organizacji danych w sposób przestrzenny.



Rysunek 10.3: Schemat architektury bloku kompresji przestrzennej w zaproponowanej walidacyjnej sieci neuronowej.

### Blok przetwarzania informacji przestrzennej

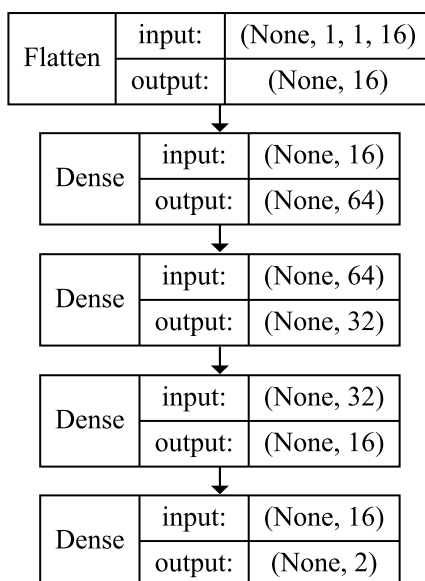
Dane ułożone w przestrzeń dwuwymiarową z kanałami wymuszoną poprzez blok kompresji przestrzennej są następnie wykorzystane w bloku, który został zaprojektowany z myślą o przetwarzaniu uzyskanych zależności przestrzennych. Z tego powodu dane są przetwarzane przez dwuwymiarowe warstwy splotowe z jądrem  $3 \times 3$ . Architektura tego bloku przedstawiona jest na rysunku 10.4.



Rysunek 10.4: Schemat architektury bloku przetwarzania informacji przestrzennej w zaproponowanej walidacyjnej sieci neuronowej.

### Blok końcowego przetwarzania dla sygnału prędkości liniowej i obrotowej

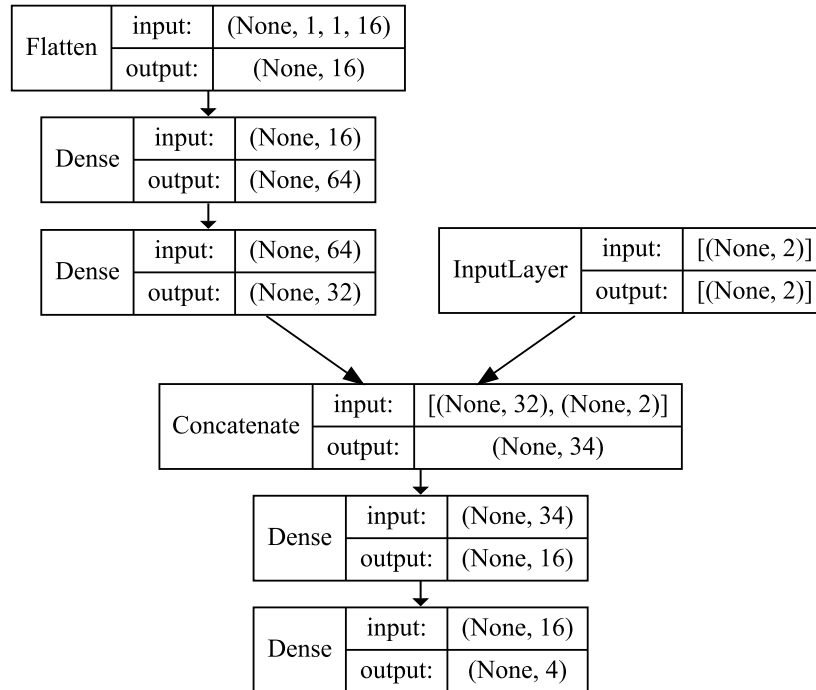
Gęste warstwy z aktywacjami w postaci funkcji leaky ReLU, ReLU oraz sigmoid zastosowanymi w końcowej części służą do estymacji prędkości i prędkości obrotowej pojazdu. Schemat tego bloku przedstawiono na rysunku 10.5. Pełna sieć estymacji prędkości i prędkości obrotowej zawiera 49086 parametrów.



Rysunek 10.5: Schemat architektury bloku końcowego przetwarzania w celu uzyskania estymaty prędkości liniowej i obrotowej pojazdu.

### Blok końcowego przetwarzania dla detekcji i klasyfikacji anomalii

Końcowe warstwy sieci walidacji danych są zbudowane z dwóch gęstych warstw z aktywacją leaky ReLU, połączonych z sygnałami prędkości pojazdu i prędkości obrotowej. Otrzymane dane są następnie przetwarzane przez dwie gęste warstwy z aktywacjami ReLU i softmax. Warstwę decyzyjną przedstawiono na rysunku 10.6. Końcowa sieć posiada 49152 parametry.



Rysunek 10.6: Schemat architektury bloku końcowego przetwarzania w celu detekcji i klasyfikacji anomalii.


### 10.1.2 Uzyskane wyniki sieci walidacyjnej

#### Estymacja prędkości liniowej oraz kątowej pojazdu


Sieć neuronowa została wytrenowana na zwalidowanych danych prędkości pojazdu oraz prędkości obrotowej. Dane walidacyjne wykluczały wszelkie potencjalnie uszkodzone próbki, w tym te, w których pojazd był raportowany jako nieruchomy, aby wyeliminować ewentualne utraty danych podczas transmisji. Stosunek danych treningowych do walidacyjnych wynosił 7 : 3. Próbki danych uwzględnione w treningu zostały ograniczone do 883 tysięcy z początkowych 1,07 miliona w zbiorze danych.

Trening przeprowadzono z użyciem optymalizatora Adam oraz funkcji celu będącej błędem średniokwadratowym z współczynnikiem uczenia  $10^{-4}$ . Po 53 epokach osiągnięto wartość optymalną, a końcowa wartość błędu średniokwadratowego dla walidacji wyniosła  $7,6429 \cdot 10^{-4}$ , a średni błąd bezwzględny: 0,0092.

Po zakończeniu treningu sieć została wykorzystana do predykcji wartości prędkości i prędkości obrotowej dla całego zbioru danych, a uzyskane estymacje posłużyły do obliczenia residuów. Następnie zostały one użyte w celu otrzymania funkcji gęstości prawdopodobieństwa, przedstawionego na rysunkach 10.7 oraz 10.8.



Rysunek 10.7: Funkcja gęstości prawdopodobieństwa błędu prędkości pojazdu wyestymowanej za pomocą zaproponowanej sieci neuronowej.



Rysunek 10.8: Funkcja gęstości prawdopodobieństwa błędu prędkości obrotowej pojazdu wyestymowanej za pomocą zaproponowanej sieci neuronowej.

### Detekcja i klasyfikacja anomalii


Dane treningowe do weryfikacji integralności danych zostały przygotowane z losowo zniekształconymi wartościami, aby zapewnić kontrolowane etykiety dla anomalii w danych. Wejścia do algorytmu zostały uszkodzone przez:

- zastąpienie prędkości radialnej każdej poprawnej detekcji w skanie losową liczbą (klasa 0);
- zastąpienie prędkości pojazdu zastąpione losową liczbą (klasa 1);
- zastąpienie prędkości obrotowej pojazdu przez losową liczbę (klasa 2).

W przypadku, gdy nie zastosowano żadnego zniekształcenia, jako etykiety przypisywano klasę 3.

Trening przeprowadzono z użyciem optymalizatora Adam, funkcji straty kategoriowej entropii krzyżowej oraz współczynnika uczenia 0,001. Po 28 epokach model osiągnął optimum z wartością straty

walidacyjnej 0,1653 i dokładnością klasyfikacji 95,23%. Dalsze próby dostrojenia sieci przeprowadzono z współczynnikiem uczenia  $10^{-5}$  bez widocznej poprawy. Przewidywane wartości skonfrontowane z rzeczywistymi etykietami są dostępne na rysunku 10.9. Wyniki w macierzy błędów przedstawiają interesujące spostrzeżenia, że sieć neuronowa nie ma problemów z wykrywaniem manipulacji w prędkościach radialnych detekcji.



Rysunek 10.9: Macierz błędów dla sieci walidacyjnej. Klasy: 0 - dane z zaburzoną prędkością radialną, 1 - dane z zaburzoną prędkością pojazdu, 2 - dane z zaburzoną prędkością obrotową pojazdu, 3 - dane bez wprowadzonego błędu.

Zaprezentowana minimalistyczna sieć konwolucyjna może oszacować chwilową prędkość pojazdu oraz prędkość obrotową z dokładnością wystarczającą do dostarczenia wglądu na potrzeby walidacji danych. Wyniki detekcji anomalii zawierają w sobie niepoprawnie wykryte anomalie, ale mogą pozwolić na wykrycie nagrań zawierających w sobie błędy estymacji. Jakość zaproponowanej sieci może polepszyć:

- udoskonalenie metody manipulacji danymi w celu dostarczenia bardziej realistycznych anomalii;
- uzyskanie dodatkowych danych, które są uszkodzone w sposób naturalny, a nie syntetyczny wraz z dostarczonymi anotacjami anomalii;
- zmodyfikowanie architektury, tak aby uwzględniała wejścia z wielu instancji czasowych.

## 10.2 Otwarte zbiory danych radarowych

Na przestrzeni ostatniej dekady powstało kilka otwartych zbiorów danych, które umożliwiają pracę nad algorytmami stosowanymi w aktywnym bezpieczeństwie i jeździe autonomicznej. Są to:

1. **RadarScenes** – zbiór zawierający dane radarowe oraz obraz z otaczających kamer [262];
2. **nuScenes** – zbiór oferujący dane o obiektach radarowych, lidarowe oraz z kamer [263];
3. **Oxford Radar RobotCar Dataset** – zbiór zawierający dane z radaru 360 [°], lidarów i kamer [264];
4. **CARRADA** – zbiór danych zawierający dane radarowe na poziomie kąta nadejścia – prędkości radialnej połączony z obrazem wideo [265];
5. **RADIATE Dataset** – zbiór danych zawierający radar 360 [°], lidar 360 [°] oraz kamerę stereowizyjną [266];
6. **TJ4DRadSet** – zbiór danych zawierający dane z radaru, lidar 360 [°] oraz kamery, zawiera on tylko 7757 skanów [267].

Istnieją również inne, mniej znane zbiory danych, jednak bardzo często są one bardzo małe lub nie są aktywnie wspierane – ich dokumentacja oraz możliwość pobrania może zniknąć w każdym momencie. Z tego względu, przy wyborze zbioru pod uwagę brana była możliwość pobrania zbioru danych z wiarygodnego i stabilnego serwera oraz ich dostosowanie w kontekście projektu wdrożeniowego.

Większość rozważanych zbiorów danych nie była adekwatna do problemu poruszanego w doktoracie. Czynniki, które wpłynęły na odrzucenie danych, były:

- typy radarów o zupełnie innej charakterystyce od rozważanej w kontekście projektu wdrożeniowego, czyli radary 360 [°];
- dane radarowe w postaci nieadekwatnej do projektu, tj. range-Doppler mapy, angle-Doppler mapy;
- dane w postaci pojedynczych skanów radarowych lub bardzo krótkich sekwencji, niewystarczających do przeprowadzenia kalibracji radaru.

W wyniku analizy powyższych zbiorów danych zdecydowano się na użycie zbioru RadarScenes [262]. Jego zaletami są:

- stabilność - zbiór ten dostępny jest od wielu lat, jest dostępny do pobrania z kilku źródeł, a strona z jego dokumentacją działa bez zastrzeżeń;
- wielkość danych - zbiór składa się z 158 nagrań testowych o różnej długości, które sumują się w ponad cztery godziny jazd testowych;
- struktura danych - dane te pomimo, że nie odwzorowują idealnie projektu wdrożeniowego, też składają się z czterech radarów, a informacje są dostępne w formie sklasyfikowanych detekcji punktowych, co pozwala na ich użycie po minimalnym dostosowaniu struktury.

Do istotnych wad użytego zbioru danych należy brak pomiaru elewacji, umiejscowienie 4 czujników na przodzie pojazdu oraz brak dokładnych informacji na temat parametrów użytych radarów. Aby umożliwić testowanie algorytmów, które wymagają pomiaru elewacji, detekcje zostały rozszerzone o symulowane wartości elewacji.

### 10.3 Dane syntetyczne

Brak pomiaru elewacji w dostępnych zbiorach testowych sprawia, że konieczne jest użycie syntetycznych lub częściowo syntetycznych danych. Na rynku dostępne są narzędzia komercyjne oraz *open-source* tj. CARLA [268]. Umożliwiają one dostarczenia dokładnych danych referencyjnych oraz wizualizacji środowiska, jednak uzyskanie danych zwykle wymaga dużych zasobów sprzętowych oraz zaprojektowania środowiska. Implementacja realistycznie odwzorowanego środowiska w świecie wirtualnym jest zadaniem nietrywialnym i czasochłonnym. Pomimo niewątpliwych zalet symulacja detekcji radarowych jest często bardzo uproszczona i polega na generowaniu punktów w miejscach przecięcia regularnie rozmieszczonych ścieżek optycznych z zaimplementowanym obiektem.

W trakcie prac nad doktoratem postanowiono wykorzystać dane z otwartego zbioru Radar Scenes, a tam, gdzie konieczne jest użycie kąta elewacji, wzbogacić rzeczywiste dane o losowy kąt elewacji o dystrybucji uniformalnej pokrywającej wertykalne pole widzenia. Generacja danych syntetycznych odbywała się w następujących krokach dla każdej detekcji pochodzącej ze stacjonarnego otoczenia:

1. Generacja losowej wartości kąta elewacji  $\beta_n$  w polu widzenia sensora.
2. Dla istniejącego parametru detekcji  $\alpha_n$  i wygenerowanego  $\beta_n$  wyliczenie  $\alpha_{VCS}$  i  $\beta_{VCS}$ , wg (9.10) i (9.11) dla żądanych wartości kalibracyjnych  $\alpha_m$ ,  $\beta_m$  i  $\gamma_m$ .
3. Obliczenie prędkości radialnej  $\dot{r}$  za pomocą wzoru (9.12) wykorzystując żadaną wartość współczynnika korekcji prędkości  $k_v$ .
4. Dodanie szumu o dystrybucji normalnej do wygenerowanych parametrów.

Zaletami generacji detekcji w opisany sposób są:

- łatwość implementacji;
- niska złożoność obliczeniowa;
- możliwość zadania oczekiwanych parametrów kalibracyjnych;
- zachowanie realistycznej dystrybucji przestrzennej danych (budynki, krawężniki, barierki itd. są nadal dostępne w otoczeniu).

## Rozdział 11

# Ewaluacja opracowanych metod

Jednym z problemów związanych z pracą nad algorytmami kalibracji jest brak wiarygodnych danych referencyjnych, które są niemożliwe do zmierzenia. Intuicyjne wskaźniki jakości takie jak uchyb estymacji są niemożliwe do wyznaczenia z powodu braku urządzeń pomiarowych zdolnych do wyznaczenia przekrzywienia anteny radarowej z dokładnością o rząd większą niż opracowywane algorytmy. W przypadku oczekiwanej dokładności poniżej stopnia, należałoby użyć urządzenia o dokładności lepszej niż 0,1 stopnia.

Intuicyjnie nasuwa się pomysł bardzo dokładnego zmapowania geometrii radaru i samochodu za pomocą precyzyjnych czujników laserowych i wyznaczenia przekrzywienia radaru. Problemem w zastosowaniu takiego podejścia jest fakt, że geometria obudowy radaru nie musi odpowiadać geometrii anteny znajdującej się w jego wnętrzu. Co gorsza, obudowa, a także zderzak, za którym schowany jest radar są integralnymi komponentami wpływającymi na anteny radarowe. Ze względu na niedokładności produkcji anteny, niejednorodności materiału, skrócenie ścieżek antenowych, efekty przejścia przez obudowę radaru oraz efekty przejścia przez zderzak, kąty *misalignmentu* nie muszą odpowiadać geometrii radaru czy pojazdu. Z tego względu pomiar geometrii lub orientacji sensora wydaje się nie być najlepszą metodą uzyskania pomiarów referencyjnych dla algorytmów adiustacji.

Z tego względu w trakcie pracy skupiono się na metodach, które mogą być wykorzystane również w algorytmach kalibracyjnych przyszłych generacji, które mogą pozwalać na wyznaczenie mapy wektorowej kątów korekcji, wiążącej kąty korekty w funkcji położenia detekcji w specyficznych obszarach pola widzenia.

### 11.1 Wybrane kluczowe wskaźniki jakości

Wybrane wskaźniki jakości odpowiadają na kluczowe z punktu widzenia potencjalnego klienta parametry jakimi są czas zbiegania się wartości kalibracyjnej do wartości użytecznej oraz stabilność uzyskanej estymacji kąta. Kolejne wskaźniki jakości wybrane do analizy nie pozwalają na intuicyjne związanie ich z dokładnością algorytmu, ale mogą dostarczyć kluczowych informacji o jakości estymacji algorytmu. Jest to średnia kwadratowa residuów prędkości radialnej, skośność dystrybucji błędu prędkości radialnej oraz jej kurtoza. Wybrane parametry mogą zostać porównane z algorytmem referencyjnym oraz niewyrównanymi detekcjami w celu analizy porównawczej.

### 11.1.1 Liczba iteracji do pokonania 95% dystansu do optimum

Kluczowym parametrem pozwalającym na ocenę racjonalności zastosowania algorytmu w projekcie produkcyjnym jest liczba iteracji konieczna do jego wykonania. Zakładając, że moc obliczeniowa stosowanego procesora pozwala na ograniczoną liczbę iteracji w trakcie jednego skanu radarowego, wskaźnik ten będzie wiązał się bezpośrednio z czasem potrzebnym na kalibrację.

Ponieważ niektóre metody optymalizacji mogą dążyć do optimum niemal w nieskończoność, wykonując kroki malejące z każdą kolejną iteracją, czas potrzebny do osiągnięcia optimum może być niemożliwy do zmierzenia. Niektóre metody mogą oferować szybką zbieżność do bliskiego otoczenia optimum, ale znacznie zwalniać na ostatnim etapie optymalizacji. Z tego względu liczba iteracji brana jest dla każdego parametru na podstawie pokonania 95% drogi do optimum od punktu początkowego. Jest to więc pierwsza iteracja ( $n$ ), dla której spełnione zostaje równanie:

$$0,05 \cdot |\mathbf{b}^* - \mathbf{b}^{(0)}| \geq |\mathbf{b}^* - \mathbf{b}^{(n)}|. \quad (11.1)$$

Pozwala to na wyznaczenie kluczowego z punktu widzenia systemu czasu reakcji na błędy w wartościach kalibracyjnych, a pomija mało istotny czas końcowego dostrajania do wartości optymalnej. W przypadku, gdy nie jest możliwe zebranie danych lub zasymulowanie zadanego z góry przekrzywienia radaru należy zmienić punkty startowe algorytmu, tak aby dystans do pokonania przez optymalizator był znormalizowany.

Pomiar czasu powinien zostać wykonany po wychyleniu wszystkich zadanych parametrów do punktów początkowych o wartości:

$$\left[ k_v^{(0)} - k_v^* \quad \alpha_m^{(0)} - \alpha_m^* \quad \beta_m^{(0)} - \beta_m^* \quad \gamma_m^{(0)} - \gamma_m^* \right] = \left[ -10^{-2} \left[ \frac{1}{1} \right] \quad -3 [^\circ] \quad 3 [^\circ] \quad -3 [^\circ] \right] \quad (11.2)$$

### 11.1.2 Maksymalne odchylenie od wartości optymalnej

W przypadku większości algorytmów optymalizacji po osiągnięciu optimum następuje oscylacja parametrów wokół niego. Wartości tych odchyżeń mogą pozwolić oszacować stabilność estymacji oraz to czy algorytm jest odporny na występujące niedokładności danych pomiarowych.

### 11.1.3 Średnia kwadratowa residuów prędkości radialnej

W celu zapewnienia możliwości analizy porównawczej dwóch algorytmów należy porównać wartości residuów prędkości radialnej. Wybranie dystrybucji błędu prędkości radialnej jako parametru, dla którego wyliczane są wskaźniki jakości podyktowane jest przenaszalnością proponowanego rozwiązania. Dodatkową zaletą jest samodzielne mierzenie zarówno wartości kątowych jak i prędkości radialnej przez radar. Pozwala to na pominięcie problematycznych kwestii związanych z geometrią anteny, efektów przejścia przez ośrodki fali radarowej itd..

Obliczenie średniej kwadratowej residuów prędkości radialnej realizowane jest za pomocą powszechnie stosowanego wzoru:

$$RMSE(\dot{r}) = \sqrt{\frac{1}{N} \sum_{n=1}^N \Delta \dot{r}_n^2}, \quad (11.3)$$

gdzie  $N$  oznacza liczbę detekcji.

### 11.1.4 Skośność

Skośność jest kluczowym parametrem pozwalającym określić asymetryczność dystrybucji. Skośność równa zero oznacza dystrybucję symetryczną, ujemna oznacza wydłużone lewe ramię rozkładu, a dodatnia – prawe. Można ją wyznaczyć na podstawie ilorazu trzeciego momentu centralnego przez trzecią potęgę odchylenia standardowego:

$$A_s = \frac{\mu_3}{\sigma^3}. \quad (11.4)$$

### 11.1.5 Kurtoza

Kurtoza podobnie jak skośność pozwala ocenić jak bardzo badany rozkład zmiennej statystycznej jest różny od dystrybucji normalnej. Jest ona dana wzorem:

$$A_k = \frac{\mu_4}{\sigma^4}, \quad (11.5)$$

gdzie  $\mu_4$  oznacza czwarty moment centralny dystrybucji.

Intuicyjna interpretacja kurtozy mówi o tym, że jest to parametr pozwalający na ocenę w jaki sposób ramiona badanej dystrybucji różnią się od dystrybucji normalnej. W przypadku gdy kurtoza jest równa 3 intensywność wartości skrajnych jest podobna do intensywności wartości skrajnych rozkładu normalnego, a jeśli jest większa, intensywność wartości skrajnych jest większa od rozkładu normalnego.

## 11.2 Metoda odniesienia

Algorytm referencyjny powinien być odporny, aby zapewnić precyzyjne estymacje pomimo zakłóconych danych wejściowych, a jednocześnie być łatwy w implementacji i skuteczny w większości scenariuszy. Aby zredukować liczbę parametrów do rozważenia podczas implementacji, wybrano algorytm post-factum. Algorytm ten ma na celu rozwiązanie modelu prędkości względem zasięgu opisanego w równaniu (8.12) dla stacjonarnego środowiska ( $T_x = 0$  and  $T_y = 0$ ) w celu wyliczenia dwóch parametrów: współczynnika kompensacji prędkości ( $k_v$ ) oraz kąta niewłaściwego ustawienia azymutu. Równanie używane do oszacowania tych parametrów jest następujące:

$$f(k_v, \alpha_m) = \dot{r}_n - (V_{\omega_x} - k_v V_x) \cos \alpha_{nVCS} + V_{\omega_y} \sin \alpha_{nVCS} = 0, \quad (11.6)$$


gdzie  $V_{\omega_x}$  podobnie jak  $V_{\omega_y}$  jest składową związaną bezpośrednio z prędkością kątową pojazdu.

### 11.2.1 Wybór detekcji stacjonarnych

Kroki opisane w tej podsekcji mają na celu zidentyfikowanie detekcji stacjonarnych o wysokim poziomie pewności, niezależnie dla każdego z czujników. W celu wstępnego wyselekcjonowania interesujących detekcji, wybrano te oznaczone jako klasa „inne” i zarejestrowane w momencie, gdy prędkość pojazdu przekraczała 5 [m/s], a bezwzględne przyspieszenie było mniejsze niż 0,5 [ $m/s^2$ ]. Kolejnym krokiem była

transformacja głosująca na siatce, uwzględniająca azymut skompensowany kierunkiem czujnika oraz znormalizowaną, względem prędkości pojazdu, domenę prędkości radialnej. Skonstruowana siatka miała szerokość 100 przedziałów azymutu i wysokość 200 przedziałów prędkości radialnej. Każda detekcja zwiększała licznik w przedziale, który był powiązany z pomiarami azymutu i prędkości radialnej dla danej detekcji. Z każdej kolumny przedziałów azymutu wybierano przedział prędkości radialnej z najwyższym licznikiem. Tylko detekcje przyczyniające się do wartości licznika w wybranym zakresie przechodziły do następnego etapu. Działania te miały na celu stworzenie dokładnej estymacji krzywej detekcji stacjonarnych w domenie azymut-prędkość radialna, co jest zapewnione przez fakt, że większość detekcji radarowych dotyczy obiektów stacjonarnych, zwłaszcza gdy wszystkie ruchome klasy oznaczone w zestawie danych zostały usunięte podczas fazy wstępnej selekcji.

Detekcje wybrane w poprzedniej fazie były używane do dopasowania wielomianu piątego rzędu. Dopasowane funkcje wielomianowe były stosowane do oszacowania oczekiwanej prędkości radialnej detekcji stacjonarnych. Prędkość radialna dla detekcji wcześniej zaklasyfikowanych jako „inne” była oceniana względem przewidywanej krzywej wielomianowej, a tylko detekcje o bezwzględnym odchyleniu mniejszym niż 0,05 m/s były brane pod uwagę w dalszych obliczeniach. Wyniki działania algorytmu zostały przedstawione na rysunku 11.1.



Rysunek 11.1: Ilustracja przedstawiająca początkowe dane wejściowe dla algorytmu wyboru detekcji stacjonarnych (kolor niebieski), wybrane detekcje (kolor pomarańczowy) oraz oczekiwaną krzywą detekcji stacjonarnych (kolor złoty). Detekcje radarowe pochodzące z RadarScenes—Sekwencja 1.

### 11.2.2 Metoda optymalizacji w algorytmie referencyjnym

Parametry równania (11.6) zostały oszacowane za pomocą techniki nieliniowych najmniejszych kwadratów (NLS). Konieczne jest wyprowadzenie macierzy Jacobiego dla danego modelu, zbudowanej na podstawie

pochodnych równania (11.6):

$$\frac{\partial f}{\partial k_v} = V_x \cos(\alpha_b + \alpha_n + \alpha_m), \quad (11.7)$$


$$\frac{\partial f}{\partial \alpha_m} = (V_{\omega_x} - k_v V_x) \sin(\alpha_b + \alpha_n + \alpha_m) + V_{\omega_y} \cos(\alpha_b + \alpha_n + \alpha_m). \quad (11.8)$$

Macierze Jacobiego są konstruowane z wykorzystaniem pochodnych z równań (11.7) i (11.8), bazując na 256 losowo wybranych stacjonarnych detekcjach dla każdego czujnika, tworząc w ten sposób macierz o wymiarach  $256 \times 2$  dla pojedynczego czujnika.

Algorytm działa iteracyjnie, wybierając losowy podzbiór detekcji z każdego radaru i udoskonalając oszacowania. Aby precyzyjnie obliczyć współczynnik kompensacji prędkości, który jest parametrem wspólnym dla wszystkich czujników pojazdu, algorytm naprzemiennie wykorzystuje różne czujniki w każdej iteracji. Aby osiągnąć niezawodne oszacowanie w fazie udoskonalania parametrów, algorytm korzysta z wartości  $\mathbf{U}_{svd}$ ,  $\mathbf{\Sigma}_{svd}$ ,  $\mathbf{V}_{svd}$  uzyskanych z dekompozycji według wartości osobliwych (SVD) macierzy Jacobiego. Podczas każdej iteracji algorytmu odpowiednie wartości czujników są aktualizowane w następujący sposób:

$$\Delta_b = \mathbf{V}_{svd} \mathbf{\Sigma}_{svd}^{-1} (\mathbf{U}'_{svd} \eta \mathbf{R}_r), \quad (11.9)$$

gdzie  $\Delta_b$  reprezentuje krok aktualizacji oszacowanych parametrów, a  $\eta$  jest parametrem, który wskazuje pożądany ułamek zbieżności z rzeczywistą resztą, oznaczoną jako  $\mathbf{R}_r$ . Parametr  $\eta$  można interpretować podobnie do współczynnika uczenia w sieciach neuronowych, a w tym przypadku wybrano  $10^{-4}$  aby zapewnić stopniową, ale stałą zbieżność do ostatecznych wartości oszacowanych parametrów. Wynikowa zbieżność została przedstawiona na rysunku 11.2.




Rysunek 11.2: Ilustracja przedstawiająca zbieżność do wartości optymalnej znalezionej przez algorytm estymacji błędu kąta montażowego dla każdego czujnika, przeprowadzona na podstawie detekcji radarowych ze zbioru danych RadarScenes—Sekwencja 1.

### Wyniki metody odniesienia

Jednym z wyzwań przy opracowywaniu kluczowych wskaźników wydajności (KPI) dla adiustacji radarów jest zapewnienie, że mogą być one obliczane dla wszystkich typów radarów samochodowych. Szcze-

gólnie wartościowym wskaźnikiem KPI byłby błąd średniokwadratowy (RMSE) błędu pozycjonowania w globalnym układzie współrzędnych (GCS) w przypadku wąskich obiektów. Te obiekty mogą dostarczyć informacji o tym, jak zidentyfikowany kąt wyrównania poprawia pozycję GCS stacjonarnych celów. Aby skutecznie wykorzystać taki wskaźnik KPI, potrzebne byłyby radary mogące raportować dużą liczbę detekcji, oferować wysoką rozdzielczość azymutu i dostarczać dane z relatywnie wysoką częstotliwością. Jednakże, w przypadku zestawu danych RadarScenes, liczba dopasowanych obiektów między skanami była zbyt mała, aby wyciągnąć znaczące wnioski. Najprostsze i najbardziej przenaszalne wskaźniki KPI wydają się być związane z błędem prędkości radialnej. Nawet czujniki samochodowe niskiej klasy wydają się zapewniać dość wiarygodne oszacowanie prędkości radialnej, aby dokładnie mierzyć prędkości otaczających celów. Rysunek 11.3 pokazuje, że jeśli czujniki są przekrzywione, to rozkład błędów równania prędkości radialnej będzie się znacznie różnił od oczekiwanej dystrybucji normalnej. Ta wiedza może być wykorzystana do implementacji wskaźników KPI, które mogą być stosowane na różnych modelach czujników.



Rysunek 11.3: Funkcja gęstości prawdopodobieństwa (FGP) odchyłeń prędkości radialnej od modelu, skumulowana dla wszystkich radarów zamontowanych na pojeździe. Czujniki celowo wychylone o wartości  $\alpha_m$ : 3, -3, -2, -1 [°] (kolor niebieski), oryginalne kąty montażu (kolor pomarańczowy) oraz prawidłowo wyrównane czujniki (kolor złoty). RadarScenes—Sekwencja 1 .

Proponowany algorytm odniesienia został zastosowany do Sekwencji 1 zestawu danych RadarScenes, co pozwoliło uzyskać wartości przedstawione w Tabeli 11.1. Te wartości zostały użyte do wyrównania wszystkich detekcji w ramach Sekwencji 1 i obliczenia błędu średniokwadratowego (RMSE) na podstawie rozbieżności między oszacowaniami modelu prędkości radialnej a rzeczywistymi pomiarami prędkości radialnej. Uzyskane błędy zostały przefiltrowane, aby wykluczyć próbki powyżej  $4\sigma$ , a następnie przefiltrowane próbki zostały użyte do określenia RMSE, skośności i kurtozy. Ta sama procedura została wykonana dla detekcji, w których czujniki zostały przekrzywione o  $\alpha_m$ : 3, -3, -2, -1 stopni oraz dla oryginalnych detekcji. Wyniki tego porównania przedstawiono w Tabeli 11.2.

Tabela 11.1: Wyniki proponowanego algorytmu odniesienia dla RadarScenes—Sekwencja 1.

<b>Radar</b>	$\alpha_m$ [°]	$k_v$ [1/1]
1	-0,0563	
2	-0,4072	1,001430
3	0,1563	
4	0,0462	

Tabela 11.2: Wyniki KPI proponowanego algorytmu odniesienia dla trzech rozważanych przypadków: detekcje umyślnie wykrzywione, detekcje oryginalne i detekcje wyrównane. Odchylenia ze wszystkich radarów zostały wspólnie ocenione zgodnie z KPI. Na podstawie RadarScenes—Sekwencja 1.

	<b>Wychylone detekcje</b>	<b>Oryginalne detekcje</b>	<b>Wyrównane detekcje</b>
RMSE	0,2398	0,0841	0,0831
Skośność	-0,6984	-0,5062	-0,3702
Kurtoza	4,6539	6,6103	6,6366

Procedurę opisaną w tej podsekcji można powtórzyć dla różnych algorytmów i ewentualnie różnych zestawów danych, aby pokazać różnicę w błędach prędkości radialnej dla detekcji stacjonarnych. Algorytm przedstawiony tutaj jest na tyle uniwersalny, że można go odtworzyć i wykorzystać jako punkt odniesienia nawet z zestawem danych, który nie został uwzględniony w tym doktoracie.


### 11.3 Wyniki trójosiowej kalibracji post-factum z kompensacją prędkości na danych rzeczywistych

Pomimo istnienia złożonych i wyrafinowanych metod generowania danych syntetycznych weryfikacja każdego problemu powinna być w miarę możliwości potwierdzona na danych rzeczywistych, które nie podlegają żadnym modyfikacjom. Mimo braku wiarygodnej referencji kąta misalignmentu na danych rzeczywistych, działanie algorytmu może zostać udowodnione poprzez spadek błędu prędkości radialnej na detekcjach stacjonarnych.


Zaimplementowany algorytm post-factum został uruchomiony na sekwencji 1 datasetu RadarScenes. Uzyskane końcowe wyniki algorytmu optymalizacji są przedstawione w tabeli 11.3. Pomimo chaotycznych początkowych poszukiwań algorytm znalazł optimum, co można zaobserwować dla parametrów  $k_v$ ,  $\alpha_m$ ,  $\beta_m$ ,  $\gamma_m$  na rysunkach 11.4, 11.5, 11.6 i 11.7. Wyniki KPI dla algorytmu zestawione z wynikami dla oryginalnych detekcji i algorytmu referencyjnego są przedstawione w tabeli 11.4. Jak można z nich wywnioskować, zaimplementowany algorytm post-factum poprawił średnią kwadratową (RMSE), bardziej niż algorytm referencyjny. Dowodzi to postawionej tezy, że trójosiowa kalibracja jest w stanie poprawić detekcje bardziej niż kalibracja samego kąta horyzontalnego.

Tabela 11.3: Uzyskane wyniki estymat algorytmu trójosiowej kalibracji post-factum z kompensacją prędkości. Na podstawie RadarScenes—Sekwencja 1.


Radar	$k_v$ [1/1]	$\alpha_m$ [°]	$\beta_m$ [°]	$\gamma_m$ [°]
1	1,001701	-0,1107	0,7718	-0,9464
2		-0,0318	5,4810	-1,6579
3		-1,6579	2,3537	-1,3493
4		-0,1003	-1,1381	-0,0865




Rysunek 11.4: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $k_v$  znalezionej przez algorytm post-factum. RadarScenes—Sekwencja 1.



Rysunek 11.5: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\alpha_m$  znalezionej przez algorytm post-factum. RadarScenes—Sekwencja 1.



Rysunek 11.6: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\beta_m$  znalezionej przez algorytm post-factum. RadarScenes—Sekwencja 1.



Rysunek 11.7: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\gamma_m$  znalezionej przez algorytm post-factum. RadarScenes—Sekwencja 1.

Tabela 11.4: Wyniki KPI algorytmu trójosiowej kalibracji post-factum z kompensacją prędkości. Na podstawie RadarScenes—Sekwencja 1.

	Oryginalne detekcje	Algorytm referencyjny	Algorytm post-factum
Zbieżność [iteracje]		24428	16403
Wychylenie $k_v$ [1/1]		$2,32 \cdot 10^{-5}$	$9,82 \cdot 10^{-5}$
Wychylenie $\alpha_m$ [°]		0,0194	0,0106
Wychylenie $\beta_m$ [°]		—	0,1851
Wychylenie $\gamma_m$ [°]		—	0,1663
RMSE	0,0841	0,0831	0,0826
Skośność	-0,5062	-0,3702	-0,4835
Kurtoza	6,6103	6,6366	6,4978

## 11.4 Wyniki uzyskane na danych syntetycznych

Opracowana metoda wzbogacania detekcji o losową elewację została wykorzystana przy użyciu parametrów w tabeli 11.5. Symulowane w ten sposób detekcje wzbogacone o pomiar elewacji i z góry zdefiniowaną wartością przekrzywienia zostały użyte do wyznaczenia KPI. Algorytmy na danych syntetycznych to:

1. **Metoda gradientowa największego spadku** - wyniki obliczeń znajdują się w tabeli 11.6; zbieżność algorytmów przedstawiona jest na wykresach 11.8, 11.9, 11.10, 11.11; uzyskane KPI są przedstawione w tabeli 11.7;
2. **Nieliniowa metoda najmniejszych kwadratów** - wyniki obliczeń znajdują się w tabeli 11.8; zbieżność algorytmów przedstawiona jest na wykresach 11.12, 11.13, 11.14, 11.15; uzyskane KPI są przedstawione w tabeli 11.9;
3. **Nieliniowa metoda całkowitych najmniejszych kwadratów** - wyniki obliczeń znajdują się w tabeli 11.10; zbieżność algorytmów przedstawiona jest na wykresach 11.16, 11.17, 11.18, 11.19; uzyskane KPI są przedstawione w tabeli 11.11;
4. **Metoda sympleksu Nelder-Meada** - wyniki obliczeń znajdują się w tabeli 11.12; zbieżność algorytmów przedstawiona jest na wykresach 11.20, 11.21, 11.22, 11.23; uzyskane KPI są przedstawione w tabeli 11.13.

Wyniki przedstawionych algorytmów zostaną omówione w sekcji 11.5, aby zapewnić czytelność pracy.


Tabela 11.5: Spodziewane wartości obliczeń symulacyjnych, zdefiniowane jako parametry do algorytmu wzbogacania detekcji zastosowanego na sekwencji 1 datasetu RadarScenes.

Radar	$k_v$ [1/1]	$\alpha_m$ [°]	$\beta_m$ [°]	$\gamma_m$ [°]
1		-1	1	2
2	1,01	2	-1	1
3		1	2	-1
4		-2	-2	-2


### 11.4.1 Dynamiczna trójosiowa adiustacja z kompensacją prędkości - metoda największego spadku

Tabela 11.6: Uzyskane wyniki estymat dynamicznej kalibracji z kompensacją prędkości metodą największego spadku. Na podstawie wzbogaconej syntetycznie sekwencji 1 datasetu RadarScenes.


Radar	$k_v$ [1/1]	$\alpha_m$ [°]	$\beta_m$ [°]	$\gamma_m$ [°]
1	1,0098	-1,0080	1,0911	1,9908
2		1,9951	-0,9585	0,8358
3		1,0115	2,0654	-0,9793
4		-2,0150	-2,0052	-1,9783




Rysunek 11.8: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $k_v$  znalezionej przez algorytm gradientowy największego spadku.



Rysunek 11.9: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\alpha_m$  znalezionej przez algorytm gradientowy największego spadku.



Rysunek 11.10: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\beta_m$  znalezionej przez algorytm gradientowy największego spadku.



Rysunek 11.11: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\gamma_m$  znalezionej przez algorytm gradientowy największego spadku.


Tabela 11.7: Wyniki KPI algorytmu dynamicznej kalibracji z kompensacją prędkości metodą największego spadku. Na podstawie wzbogaconej syntetycznej sekwencji 1 datasetu RadarScenes.

	Oryginalne detekcje	Algorytm referencyjny	Algorytm NS
Zbieżność [iteracje]		24379	51183
Wychylenie $k_v$ [1/1]		$6,6303 \cdot 10^{-6}$	$7,9395 \cdot 10^{-6}$
Wychylenie $\alpha_m$ [°]		0,0184	0,0245
Wychylenie $\beta_m$ [°]		—	0,0901
Wychylenie $\gamma_m$ [°]		—	0,0694
RMSE	0,2045	0,0275	0,0272
Skośność	0,2459	-0,0271	-0,0107
Kurtoza	2,1019	3,1994	3,1990


### 11.4.2 Dynamiczna trójosiowa adiustacja z kompensacją prędkości - nieliniowa metoda najmniejszych kwadratów

Tabela 11.8: Uzyskane wyniki estymat dynamicznej kalibracji z kompensacją prędkości nieliniową metodą najmniejszych kwadratów. Na podstawie wzbogaconej syntetycznie sekwencji 1 datasetu RadarScenes.


Radar	$k_v$ [1/1]	$\alpha_m$ [°]	$\beta_m$ [°]	$\gamma_m$ [°]
1	1,0098	-0,9962	1,0254	2,0265
2		1,9770	-1,1408	1,3063
3		1,0087	2,0221	-0,9110
4		-1,9969	-2,0137	-1,9904




Rysunek 11.12: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $k_v$  znalezionej przez nieliniową metodę najmniejszych kwadratów.



Rysunek 11.13: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\alpha_m$  znalezionej przez nieliniową metodę najmniejszych kwadratów.



Rysunek 11.14: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\beta_m$  znalezionej przez nieliniową metodę najmniejszych kwadratów.



Rysunek 11.15: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\gamma_m$  znalezionej przez nieliniową metodę najmniejszych kwadratów.


Tabela 11.9: Wyniki KPI algorytmu dynamicznej kalibracji z kompensacją prędkości nieliniową metodą najmniejszych kwadratów. Na podstawie wzbogaconej syntetycznej sekwencji 1 datasetu RadarScenes.

	Oryginalne detekcje	Algorytm referencyjny	Algorytm NLS
Zbieżność [iteracje]		24379	46844
Wychylenie $k_v$ [1/1]		$6,6303 \cdot 10^{-6}$	$2,6155 \cdot 10^{-4}$
Wychylenie $\alpha_m$ [°]		0,0184	0,0715
Wychylenie $\beta_m$ [°]		—	0,1016
Wychylenie $\gamma_m$ [°]		—	0,0703
RMSE	0,2045	0,0275	0,0273
Skośność	0,2459	-0,0271	-0,304
Kurtoza	2,1019	3,1994	3,2139


### 11.4.3 Dynamiczna trójosiowa adiustacja z kompensacją prędkości - nieliniowa metoda całkowitych najmniejszych kwadratów

Tabela 11.10: Uzyskane wyniki estymat dynamicznej kalibracji z kompensacją prędkości nieliniową metodą całkowitych najmniejszych kwadratów. Na podstawie wzbogaconej syntetycznie sekwencji 1 datasetu RadarScenes.

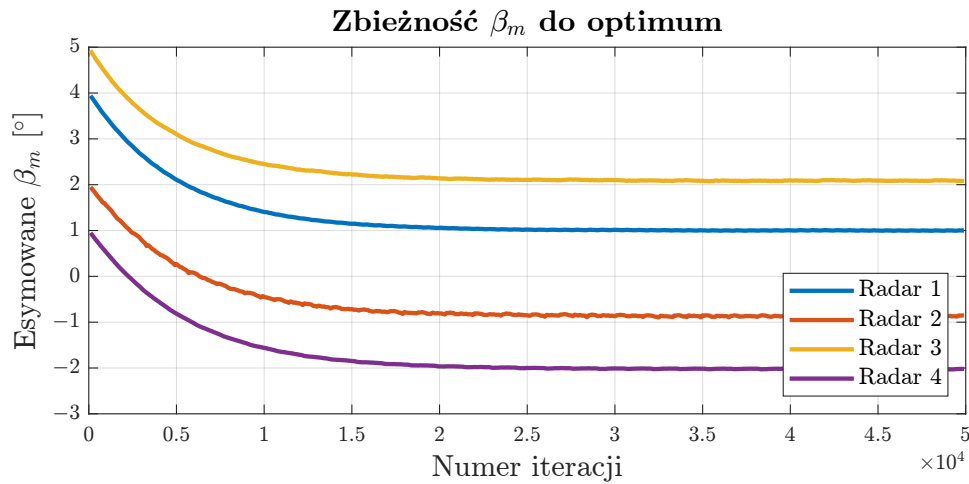
Radar	$k_v$ [1/1]	$\alpha_m$ [°]	$\beta_m$ [°]	$\gamma_m$ [°]
1	1,0098	-1,0015	1,0008	1,9605
2		1,9945	-0,8949	0,7041
3		0,9936	2,0848	-0,7618
4		-2,0006	-2,0209	-1,9876




Rysunek 11.16: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $k_v$  znalezionej przez nieliniową metodę całkowitych najmniejszych kwadratów.



Rysunek 11.17: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\alpha_m$  znalezionej przez nieliniową metodę całkowitych najmniejszych kwadratów.



Rysunek 11.18: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\beta_m$  znalezionej przez nieliniową metodę całkowitych najmniejszych kwadratów.



Rysunek 11.19: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\gamma_m$  znalezionej przez nieliniową metodę całkowitych najmniejszych kwadratów.


Tabela 11.11: Wyniki KPI algorytmu dynamicznej kalibracji z kompensacją prędkości nieliniową metodą całkowitych najmniejszych kwadratów.

	Oryginalne detekcje	Algorytm referencyjny	Algorytm TLS
Zbieżność [iteracje]		24379	15261
Wychylenie $k_v$ [1/1]		$6,6303 \cdot 10^{-6}$	$2,0410 \cdot 10^{-5}$
Wychylenie $\alpha_m$ [°]		0,0184	0,0074
Wychylenie $\beta_m$ [°]		—	0,0529
Wychylenie $\gamma_m$ [°]		—	0,1306
RMSE	0,2045	0,0275	0,0273
Skośność	0,2459	-0,0271	-0,0239
Kurtoza	2,1019	3,1994	3,2164


#### 11.4.4 Dynamiczna trójosiowa adiustacja z kompensacją prędkości - metoda sympleksu Nelder-Meada

Tabela 11.12: Uzyskane wyniki estymat dynamicznej kalibracji z kompensacją prędkości metodą sympleksu Nelder-Meada.


Radar	$k_v$ [1/1]	$\alpha_m$ [°]	$\beta_m$ [°]	$\gamma_m$ [°]
1	1,0098	-1,0006	1,0624	1,9483
2		1,9997	-1,0517	1,1350
3		1,0010	1,9636	-0,9833
4		-2,0007	-1,9570	-1,9935




Rysunek 11.20: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $k_v$  znalezionej przez algorytm sympleksu Nelder-Meada.



Rysunek 11.21: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\alpha_m$  znalezionej przez algorytm sympleksu Nelder-Meada.



Rysunek 11.22: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\beta_m$  znalezionej przez algorytm sympleksu Nelder-Meada.



Rysunek 11.23: Ilustracja przedstawiająca zbieżność do wartości optymalnej  $\gamma_m$  znalezionej przez algorytm sympleksu Nelder-Meada.

Tabela 11.13: Wyniki KPI algorytmu dynamicznej kalibracji z kompensacją prędkości metodą sympleksu Nelder-Meada.

	Oryginalne detekcje	Algorytm referencyjny	Algorytm sympleks
Zbieżność [iteracje]		24379	6971
Wychylenie $k_v$ [1/1]		$6,6303 \cdot 10^{-6}$	$2,9854 \cdot 10^{-5}$
Wychylenie $\alpha_m$ [°]		0,0184	0,0106
Wychylenie $\beta_m$ [°]		—	0,1380
Wychylenie $\gamma_m$ [°]		—	0,0912
RMSE	0,2045	0,0275	0,0272
Skośność	0,2459	-0,0271	-0,0201
Kurtoza	2,1019	3,1994	3,2126

## 11.5 Analiza wyników

Na podstawie wyników KPI można zauważyć, że wszystkie analizowane algorytmy poprawiają jakość detekcji poprzez estymację trójosiowego misalignmentu w kontekście błędu średniokwadratowego. Zastosowane metody wyróżniają się specyficznymi cechami, które mogą decydować o ich użyteczności w środowisku produkcyjnym.

Metoda największego spadku, choć jest obliczeniowo prosta, charakteryzuje się dużymi wahaniami spowodowanymi szumem pomiaru, który znacząco wpływa na gradienty. Z tego powodu kroki stosowane w tej metodzie muszą być odpowiednio małe, by zapewnić zbieżność. Skutkuje to niezadowalającą liczbą iteracji potrzebnych do osiągnięcia pobliża optimum. Rysunki 11.10 oraz 11.11 dodatkowo wskazują, że zarówno wertykalne odchylenie i skrócenie radaru w niektórych przypadkach wymaga dużej liczby iteracji.


Nieliniowa metoda najmniejszych kwadratów jest zdolna do estymacji współczynnika kompensacji prędkości w bardzo szybki i precyzyjny sposób. Niestety, gradienty związane z elewacją i skróceniem najprawdopodobniej są znacznie mniejsze niż w przypadku azymutu i prędkości pojazdu, co sprawia, że model zbiega się w tych parametrach wolniej, a co więcej, końcowe estymacje są obciążone uchybem, co można zaobserwować w przypadku estymacji związanej z radarem 2 na rysunku 11.15.

Nieliniowa metoda całkowitych najmniejszych kwadratów, wydaje się bardzo obiecująca ze względu na stabilność estymaty, która podąża do optimum bez błędzenia w przestrzeni parametrów. Niestety jej wdrożenie w środowisku wbudowanym jest niemożliwe, ponieważ zadowalające rezultaty, takie jak na rysunkach 11.16, 11.17, 11.18 i 11.19, wymagają co najmniej 128 detekcji w macierzy Jacobiego. Sprawia to, że metoda ta jest niemożliwa do wykonania na większości procesorów wbudowanych.


Ostatnią z rozważanych we wdrożeniu metod był sympleks Nelder-Meada. Jest on prosty obliczeniowo, ponieważ daje zadowalające rezultaty, co widać na rysunkach 11.20, 11.21, 11.22 i 11.23 już przy użyciu zaledwie 16 detekcji w funkcji kosztu. Niewątpliwą zaletą jest brak konieczności obliczania kosztownych gradientów, które są wrażliwe na szum. Metoda sympleksu charakteryzuje się ważną cechą – szybkością działania. Bardzo szybko reaguje na potrzebę zmiany parametrów, a początkowe szumy można zredukować, stosując wydajne metody filtracji sygnału.

Fakt, że metoda sympleksu jest najkorzystniejszym rozwiązaniem przedstawia również analiza porównawcza przedstawiona na rysunku 11.24. Można na nim zauważyć:


- czas potrzebny do pokonania 95% dystansu do optimum, gdzie najlepsze wyniki osiągają algorytmy sympleksu i nieliniowych całkowitych kwadratów, jednak należy pamiętać, że metoda sympleksu jest znacznie wydajniejsza obliczeniowo;
- uchyb estymacji  $\alpha_m$  jest najmniejszy dla metody sympleksu, a metoda nieliniowych całkowitych kwadratów zajmuje drugie miejsce;
- w przypadku uchybu  $\beta_m$  różnice pomiędzy algorytmami się zmniejszają, lecz algorytm sympleksu ma nadal przewagę;
- dla kąta skrócenia radaru  $\gamma_m$  widać znaczące pogorszenie estymacji w przypadku metod najmniejszych kwadratów, a algorytm sympleksu nadal daje najlepsze rezultaty.



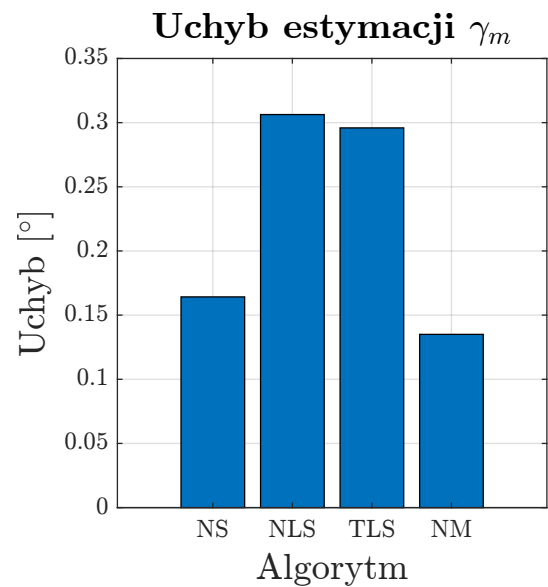
(a) Liczba iteracji potrzebna do pokonania 95% dystansu do optimum.



(b) Odchylenie wartości  $\alpha_m$  z końcowej iteracji od wartości oczekiwanej.



(c) Odchylenie wartości  $\beta_m$  z końcowej iteracji od wartości oczekiwanej.



(d) Odchylenie wartości  $\gamma_m$  z końcowej iteracji od wartości oczekiwanej.

Rysunek 11.24: Algorytmy: 1D - Referencyjny, NS - największego spadku, NLS - nieliniowy najmniejszych kwadratów, TLS - nieliniowy całkowitych najmniejszych kwadratów, NM - sympleks Nelder-Mead.



## Rozdział 12

# Podsumowanie

Przemysł motoryzacyjny od wielu lat kładzie nacisk na zwiększanie komfortu i bezpieczeństwa pojazdów i nic nie wskazuje na to, by ten trend był zagrożony wygaśnięciem. Innowacje obejmujące rynek samochodowy są motorem napędowym innych dziedzin nauki i przemysłu, wpływając na rozwój układów scalonych, technik obliczeniowych, komunikacji i sensorów umożliwiających percepcje otoczenia.

Rosnąca liczba funkcjonalności systemów wspomagania kierowcy i ciągłe dążenie do zwiększania poziomu autonomii w opracowywanych systemach wymusza nie tylko zwiększenie mocy obliczeniowej, ale także zwiększenie możliwości systemów percepcji. Skuteczne działanie systemów aktywnego bezpieczeństwa i jazdy autonomicznej możliwe jest tylko poprzez zapewnienie bardzo dokładnej informacji o obserwowanym otoczeniu. Postępy w konstrukcjach radarów umożliwiają budowę małych, precyzyjnych i energooszczędnych urządzeń. Radary, podobnie jak inne czujniki montowane na ruchomych platformach i współpracujące w ramach jednego systemu, wymagają precyzyjnego montażu, aby dostarczać informacje o otoczeniu we wspólnym układzie współrzędnych. Z tego powodu konieczne jest monitorowanie ich orientacji względem układu pojazdu, reagowanie na niespodziewane zmiany i aplikowanie korekcji na detekcjach radarowych.

Prace w trakcie przeprowadzonego projektu wdrożeniowego obejmowały zadania związane z dwiema głównymi metodami kalibracji. Obie z nich wymagały zapoznania się nie tylko z wąską dziedziną algorytmów kalibracyjnych, ale także szerokiego zrozumienia tematu przetwarzania detekcji w powszechnie stosowanych radarach FMCW. Kluczowe było również zrozumienie wpływu środowiska pojazdu na pomiary radarowe. W zależności od typu otoczenia radary są narażone na różne czynniki, które sprawiają, że detekcje radarowe z wartościowych dla systemu obiektów mogą zanikać pośród wielu obiektów, które nie mają wartości dla algorytmu. Problematyka ta jest znana zarówno w środowisku linii produkcyjnej, w której pojazd jest otoczony przez powierzchnie metalowe wpływające destruktywnie na jakość pomiaru jak i w trakcie jazdy, gdzie ważne obiekty tj. piesi i rowerzyści często mają taki sam RCS, co nic nie znaczące przedmioty, zaszumiające percepcję otoczenia.

Pierwszym typem kalibracji poruszonym w trakcie tego doktoratu była kalibracja na linii produkcyjnej oraz w autoryzowanym warsztacie samochodowym, która podlegała surowym wymaganiom producenta samochodu co do czasu wykonania procedury, powierzchni, na której może odbywać się kalibracja oraz jej odporności na zakłócenia. Środowisko działania algorytmu okazało się być bardzo wymagające i zawierało

niemożliwe do usunięcia czynniki zakłócające fazę odbijanej fali radarowej. W wyniku analiz danych okazało się, że z poziomu algorytmów radarowych nie ma możliwości wykrycia i skorygowania niedokładności pomiaru kąta azymutu celu kalibracyjnego, ponieważ żaden z parametrów detekcji radarowej nie odbiegał od oczekiwanych. Z tego względu wprowadzono innowacje, polegającą na wykorzystaniu iteracyjnego algorytmu średniej odpornej, który pozwolił na zminimalizowanie negatywnego wpływu. Zaprezentowane rozwiązanie zaowocowało międzynarodowym zgłoszeniem patentowym (EP4137841A1, US20230056655A1, US11933911B2, CN115707991A).

Kolejnym algorytmem opracowanym w trakcie prac wdrożeniowych była metoda nienadzorowanej kalibracji, pozwalająca na monitorowanie stanu sensora w sposób ciągły podczas codziennej jazdy samochodu. Algorytm ten wiąże się z kilkoma kluczowymi problemami np. zapewnieniem stabilności algorytmu przy jednoczesnym zapewnieniu szybkiej reakcji systemu na nagłe zmiany orientacji sensora. Pogodzenie tych dwóch sprzecznych wymagań jest możliwe tylko przy zapewnieniu odpowiedniej filtracji detekcji wejściowych oraz wybór odpowiedniego modelu oraz metod optymalizacyjnych. Takie decyzje mogą zostać podjęte tylko na podstawie szerokiej analizy problemu, co wymaga dostępu do znacznej ilości danych wejściowych. Dane z jazd testowych, szczególnie potrzebne na początkowych etapach projektu, mogą podlegać błędom związanym z niedojrzałością platformy testowej, wpływając negatywnie na analizę lub wydajność zespołu poprzez konieczność czasochłonnej, ręcznej walidacji pomiarów. Problem pracochłonnych i powtarzalnych analiz danych można rozwiązać poprzez wdrożenie właściwie zaprojektowanej i wytrenowanej sieci neuronowej zdolnej do detekcji anomalii w danych testowych. Nacisk położony na mały rozmiar sieci neuronowej, może prowadzić do opracowania wydajnych metod walidacji danych.

Dotychczasowe metody kalibracji radaru opisane w literaturze i patentach były zdolne do adiustacji radaru tylko w kącie horyzontalnym, a w przypadku niektórych metod - w kącie horyzontalnym i wertykalnym. Ograniczenie kalibracji do tych dwóch osi sprawia, że fizyczne skręcenie radaru staje się niemożliwe do skorygowania. Wprowadzoną innowacją było zaprojektowanie modelu matematycznego trójosiowej korekcji detekcji radarowych, która wprowadzona do równania na prędkość radialną jest w stanie zapewnić narzędzie do trójosiowej estymacji kąta przekrzywienia radaru. Opracowane w tej dziedzinie innowacje zostały zgłoszone w międzynarodowych wnioskach patentowych (EP3907521A1, CN113608182A, EP3907522A2, EP20172809). Rozwiązywanie skorelowanych ze sobą równań jest nietrywialne i wymaga wyboru odpowiednich metod optymalizacji oraz precyzyjnego doboru parametrów algorytmu tak, aby zapewnić wysoką jakość estymacji, jednocześnie nie przekraczając możliwości obliczeniowych procesora, który zostanie przeznaczony do wykonywania zadań obliczeniowych.

Przekrzywienie kątowe detekcji radarowych jest parametrem niemożliwym do bezpośredniego zmierzenia, ponieważ brak urządzeń pomiarowych zdolnych do dostarczenia informacji referencyjnych niezbędnych do analizy jakościowej algorytmów kalibracji. Dzieje się tak, ponieważ korygowane przez algorytmy kalibracji przesunięcie kątowe detekcji jest złożone z wielu nakładających się na siebie efektów, wpływających na kierunek nadejścia fali radarowej. Do takich czynników zaliczają się zniekształcenia anteny radarowej oraz efekty wynikające z przejścia fali przez obudowę radaru i zderzak zamontowany przed nim. Choć bezpośrednio porównanie oczekiwanych i estymowanych kątów korekcji radaru na danych rzeczywistych jest niemożliwe, to w celu wyznaczenia wskaźników jakości, takich jak odchylenie standardowe czy rozkład

błędu, konieczna jest weryfikacja działania algorytmu na rzeczywistych danych. Jest to jedyny sposób, by upewnić się, że wprowadzone rozwiązania, przetestowane na danych syntetycznych, przyniosą porównywalne rezultaty na danych rzeczywistych. W związku z tym zaproponowano metryki oparte na prędkości radialnej nieruchomych obiektów w otoczeniu. Umożliwia to weryfikację działania algorytmów w większości radarów samochodowych, które charakteryzują się wysoką precyzją pomiaru prędkości radialnej.

Ostatnim, niezaplanowanym zadaniem była praca badawcza, podjęta z własnej inicjatywy, mająca na celu ocenę możliwości trójosiowej adiustacji radaru i wyznaczenia współczynnika korekcy prędkości na podstawie detekcji radarowych, bez pomiaru elewacji. W wyniku prac powstał algorytm zdolny do estymacji trzech kątów oraz współczynnika kompensacji prędkości, które użyte do wyrównania detekcji poprawiają wartość średniej kwadratowej błędów prędkości radialnej stacjonarnych detekcji.

## 12.1 Wnioski

Zaimplementowany algorytm statycznej kalibracji radaru umożliwił wykrycie wertykalnego i horyzontalnego kąta wychylenia radaru oraz dostarczenie danych o amplitudzie fali radarowej przechodzącej przez zderzak. Ze względu na wymagania producenta samochodów, wyniki pomiarów nie mogły zostać załączone do rozprawy, jednak sukces implementacji rozwiązania został potwierdzony zgłoszeniem patentowym. Nawet innowacje osiągnięte w procesie kalibracji na linii produkcyjnej nie są w stanie zastąpić algorytmów dynamicznej kalibracji radaru.

Zaproponowaną trójosiową dynamiczną kalibrację radaru z kompensacją prędkości przetestowano przy użyciu różnych optymalizatorów. Na podstawie analizy danych syntetycznych wybrano algorytm sympleksu Nelder-Meada, który nie tylko uzyskał najlepsze rezultaty, ale także charakteryzuje się niską złożonością obliczeniową i możliwością optymalizacji, co umożliwia jego implementację nawet w budżetowych procesorach sygnałowych.

Zapewnienie, że pozytywne wyniki nie biorą się z odpowiednio zaprojektowanej symulacji, a z faktycznego zjawiska, któremu może podlegać każdy radar, wymagało zaimplementowania algorytmu, który może działać na detekcjach nie posiadających pomiaru elewacji. Implementacja takiego algorytmu umożliwiła wykorzystanie otwartego zbioru danych RadarScenes, a uzyskane wyniki jasno pokazują, że detekcje mają mniejszą średnią kwadratową błędów prędkości radialnej po trójosiowej korekcie niż przed nią. To jednoznacznie dowodzi, że trójosiowa adiustacja detekcji poprawia jakość pomiarów.

Założona na początku pracy teza badawcza stwierdzała, że możliwa jest implementacja algorytmu automatycznej kalibracji radaru, który, opierając się na punktowych detekcjach radarowych, spodziewanym kącie montażu sensora oraz informacjach o kinematyce pojazdu, będzie w stanie:

- wyznaczyć trójosiowy błąd kątowy montażu i wykorzystać go do korekty pomiarów;
- utrzymać złożoność obliczeniową umożliwiającą wykonanie algorytmu na wbudowanym procesorze radarowym.

Pierwsza część tezy, dotycząca możliwości wyznaczenia trójosiowego błędu orientacji, została udowodniona:

- zarówno na danych rzeczywistych, jak i syntetycznych, poprzez wyliczenie KPI, które wskazują, że zaimplementowane metody poprawiają jakość detekcji, zmniejszając średni błąd kwadratowy prędkości radialnej;
- na danych syntetycznych, gdzie parametry zbiegały się do wartości optymalnych w oczekiwanych punktach, wyznaczonych na etapie tworzenia detekcji.

Druga część tezy, dotycząca złożoności obliczeniowej trójosiowej adiustacji, została udowodniona poprzez:

- wykazanie, że jeden z najmniej wymagających algorytmów optymalizacji bezgradientowej osiągnął najlepsze rezultaty KPI;
- implementację algorytmu w początkowym etapie projektu komercyjnego.

Teza badawcza przedstawiona w niniejszym doktoracie została jednoznacznie potwierdzona przez wyniki analiz, zgłoszenie patentowe oraz implementację wynalazku w projekcie komercyjnym.

## 12.2 Potencjalne kierunki rozwoju

Tematyka kalibracji sensorów radarowych jest szerokim zagadnieniem, które nie zostało w pełni wyczerpane w ramach tej rozprawy doktorskiej. Kierunki, w których można rozwinąć obecny stan wiedzy to:

### 1. Prace nad statyczną kalibracją

#### (a) Opracowanie metody kalibracji, która zapewniałaby lepszą separację celu od szumu otoczenia

Linia produkcyjna często otoczona jest metalowymi obiektami, których odbicia zaburzają jakość estymacji. Modyfikacja celu kalibracyjnego, umożliwiająca lepsze oddzielenie celu od otoczenia, mogłaby znacznie poprawić jakość estymacji horyzontalnego i wertykalnego kąta przekrzywienia radaru.

#### (b) Opracowanie metody pozwalającej na trójosiową adiustację na linii produkcyjnej

Przedstawiona metoda statycznej kalibracji umożliwia jedynie adiustację radaru w kącie wertykalnym i horyzontalnym. Opracowanie metodologii, która pozwoliłaby na trójosiową kalibrację pomogłoby w wykrywaniu radarów zamontowanych ze skrzyżowaniem poza dopuszczalnym zakresem.

#### (c) Badania nad aktywnymi celami kalibracyjnymi

Aktywne cele kalibracyjne, które pozwalają na generowanie fali o ściśle określonych parametrach i symulujących odbicie radarowe mogą okazać się konieczne podczas bardziej zaawansowanych metod kalibracji sensorów radarowych. Badania mające na celu obniżenie ich kosztów lub zastosowanie ich w bardziej zaawansowanych metodach kalibracji statycznej mogą okazać się korzystne.

## 2. Prace nad dynamiczną kalibracją

### (a) Badania nad lepszym modelem matematycznym

Zaproponowany model matematyczny, oparty na prędkości radialnej, mógłby zostać zastąpiony modelem pozwalającym na wyeliminowanie części funkcji trygonometrycznych. Zmiana modelu w celu zredukowania liczby operacji wprowadzających nieliniowe przekształcenia mogłaby zarówno zredukować złożoność obliczeniową, a także przyspieszyć zbieżność do optimum.

### (b) Badania nad metodami optymalizacji

Metoda sympleksu Nelder-Meada daje bardzo dobre rezultaty, jednak wraz z rosnącymi możliwościami procesorów wbudowanych możliwe będzie wdrożenie bardziej zaawansowanych metod optymalizacji, takich jak algorytmy genetyczne.

### (c) Badania nad zastosowaniem sieci neuronowych do kalibracji radaru

Rozwój układów wspierających sprzętową akcelerację obliczeń macierzowych na procesorach wbudowanych sprawia, że badania nad kalibracją radaru za pomocą głębokiej sieci neuronowej stają się uzasadnione.

### (d) Działanie na mapie range-Doppler i angle-Doppler

Opracowane algorytmy działają na punktowych detekcjach, co jest uzasadnione przede wszystkim możliwościami sprzętowymi. Detekcje punktowe nie są najbardziej korzystną formą informacji radarowej, ponieważ podczas ich kreowania odrzucona zostaje znaczna ilość danych, które znajdują się na range-Doppler i angle-Doppler mapach. Implementacja zarówno konwencjonalnych algorytmów, jak i sieci neuronowych mogłaby przynieść znaczne korzyści.

## 3. Inne

### (a) Prace nad metodami monitorowania stanu radaru

Algorytmy kalibracji są jedynie częścią metod działających w obrębie radaru, które monitorują jego stan. Znane są również między innymi algorytmy wykrywania przysłonięcia radaru. Rozwój rozwiązań umożliwiających dokładną weryfikację działania radaru oraz wiarygodności detekcji, np. w celu sprawdzenia, czy nie są one spowodowane zjawiskiem wielokrotnego odbicia fali radarowej, zanim zostaną przekazane innym komponentom systemu, mógłby poprawić jakość działania algorytmów.

### (b) Prace nad metodami automatycznej walidacji radaru

Opisana w tej rozprawie metoda oparta na sieci neuronowej wydaje się obiecująca, a jej rozwój może znacząco zwiększyć efektywność prac inżynierów. Ze względu na małą liczbę parametrów, zaprezentowana metoda skłania do rozważenia, czy automatyczna walidacja danych mogłaby zostać zaimplementowana bezpośrednio na ECU w celu weryfikacji integralności uzyskiwanych danych. Mogłoby to umożliwić ochronę systemu przed atakami, mającymi na celu zakłócenie czujników i wprowadzenie do nich nieistniejących obiektów.



# Bibliografia

- [1] J. Han, M. Choi i Y. Kwon, „40-TFLOPS artificial intelligence processor with function-safe programmable many-cores for ISO26262 ASIL-D,” *ETRI Journal*, tom 42, strony 468–479, 4 2020.
- [2] Y. Kwon, J. Yang, Y. P. Cho i inni, „Function-Safe Vehicular AI Processor with Nano Core-In-Memory Architecture,” w *2019 IEEE International Conference on Artificial Intelligence Circuits and Systems (AICAS)*, mar. 2019, strony 127–131.
- [3] M. Broy, I. H. Kruger, A. Pretschner i C. Salzmann, „Engineering Automotive Software,” *Proceedings of the IEEE*, tom 95, strony 356–373, 2 2007.
- [4] L. Pike, J. Sharp, M. Tullsen, P. C. Hickey i J. Bielman, „Secure Automotive Software: The Next Steps,” *IEEE Software*, tom 34, strony 49–55, 3 2017.
- [5] A. Haghhighatkah, M. Oivo, A. Banijamali i P. Kuvaja, „Improving the State of Automotive Software Engineering,” *IEEE Software*, tom 34, strony 82–86, 5 2017.
- [6] C.-Y. Ho, S.-C. Hsieh, M.-F. Jhong, H.-C. Kuo, C.-Y. Ting i C.-C. Wang, „A Low-Cost Antenna-in-Package Solution for 77GHz Automotive Radar Applications,” w *2019 International Conference on Electronics Packaging (ICEP)*, kw. 2019, strony 110–114.
- [7] X. Ye, X. Wang, S. Liu i A. P. Tarko, „Feasibility study of highway alignment design controls for autonomous vehicles,” *Accident Analysis & Prevention*, tom 159, strona 106 252, 2021.
- [8] X. Ding, A. Carlsen, J. Schaefer i inni, „Theory and practice: A two-channel automotive radar for three-dimensional object detection,” w *2015 European Radar Conference (EuRAD)*, wrz. 2015, strony 265–268.
- [9] L. Völker, „SOME/IP Service Discovery – The need for Service Discovery in the Vehicle,” Vector Ethernet Symposium, maj 2014. adres: [https://some-ip.com/papers/2014-05-27-DrLarsVoelker-The\\_need\\_for\\_Service\\_Discovery\\_in\\_the\\_vehicle.pdf](https://some-ip.com/papers/2014-05-27-DrLarsVoelker-The_need_for_Service_Discovery_in_the_vehicle.pdf).
- [10] M. Murad, J. Nickolaou, G. Raz, J. S. Colburn i K. Geary, „Next generation short range radar (SRR) for automotive applications,” w *2012 IEEE Radar Conference*, maj 2012, strony 214–219.
- [11] A. Talai, R. M. **Burza** i S. P. Kalli, *Radar System Calibration with Bistatic Sidelobe Compensation*, US Patent 17,407,071, lip. 2023.
- [12] R. M. **Burza** i D. Borkowski, *Methods and Systems for Determining Alignment Parameters of a Radar Sensor*, EP3907521A1, lip. 2021.

- [13] R. M. Burza, „Overview of Radar Alignment Methods and Analysis of Radar Misalignment’s Impact on Active Safety and Autonomous Systems,” *Sensors*, tom 24, numer 15, 2024. DOI: 10.3390/s24154913. adres: <https://www.mdpi.com/1424-8220/24/15/4913>.
- [14] R. M. Burza, „Application of Neural Networks for Validation of Data Integrity in Large Automotive Radar Datasets,” w *2023 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, 2023, strony 71–76. DOI: 10.23919/SPA59660.2023.10274466.
- [15] R. F. Wells, *Occupant Protection and Automobile Safety in the US since 1900*. SAE International, 2012, tom 404.
- [16] M. Akamatsu, P. Green i K. Bengler, „Automotive technology and human factors research: Past, present, and future,” *International journal of vehicular technology*, tom 2013, 2013.
- [17] A. J. Yanik, „The first 100 years of transportation safety: part 1,” *The Automobile: a Century of Progress*, 1997.
- [18] G. Niemeyer, *The Automotive Career of Ransom E. Olds* (MSU business studies). Bureau of Business i Economic Research, Graduate School of Business Administration, Michigan State University, 1963. adres: <https://books.google.pl/books?id=irMeAQAAAJ>.
- [19] E. A. Torrero, „Automating the production line: Henry Ford began it all when he designed the first car assembly line in 1914,” *IEEE Spectrum*, tom 14, numer 11, strony 71–72, 1977. DOI: 10.1109/MSPEC.1977.6501657.
- [20] W. Kamm, *Das Kraftfahrzeug*. Springer, 1936.
- [21] N. K. Ach, „Psychologie und technik bei bekämpfung von autounfällen,” *Industrielle Psychotechnik*, tom 6, numer 3, strony 87–105, 1929.
- [22] T. W. Forbes, „The normal automobile driver as a traffic problem,” *The Journal of general psychology*, tom 20, numer 2, strony 471–474, 1939.
- [23] J. Kulowski, „Orthopedic aspects of automobile crash injuries and deaths,” *Journal of the American Medical Association*, tom 163, numer 4, strony 230–233, 1957.
- [24] S. Standard, *Manikins for use in defining Vehicle seating accommodation - SAE J826*, 1962.
- [25] S. Standard, *Motor vehicle driver’s eye range - J941*, 1965.
- [26] D. C. Hammond i R. W. Roe, „Driver head and eye positions,” *SAE Transactions*, strony 786–800, 1972.
- [27] J. F. Meldrum, „Automobile driver eye position,” *SAE Transactions*, strony 599–609, 1966.
- [28] S. Standard, *Passenger car rear vision - SAE J834*, 1967.
- [29] A. J. Yanik, „The first 100 years of transportation safety: part 2,” *The Automobile: a Century of Progress*, 1997.
- [30] N. H. T. S. Administration. „Vehicle Crash Test Database: Test Number 32,” U.S. Department of Transportation. (1978), adres: <https://www.nhtsa.gov/research-data/research-testing-databases#/vehicle/32>.

- [31] G. T. Schwartz, „The myth of the Ford Pinto case,” *Rutgers L. Rev.*, tom 43, strona 1013, 1990.
- [32] M. Dowie, *Pinto madness*. Mother Jones September/October, 1977.
- [33] W. M. Hoffman, „Case study—the Ford Pinto,” *Corporate obligations and responsibilities: Everything old is new again*, strony 222–229, 1966.
- [34] J. K. Foster, J. O. Kortge i M. J. Wolanin, „Hybrid III—a biomechanically-based crash test dummy,” *SAE transactions*, strony 3268–3283, 1977.
- [35] R. R. Mourant i T. H. Rockwell, „Mapping eye-movement patterns to the visual scene in driving: An exploratory study,” *Human factors*, tom 12, numer 1, strony 81–87, 1970.
- [36] J. Versace, „A review of the severity index,” 1971.
- [37] D. C. Hammond i R. W. Roe, „SAE controls reach study,” *SAE Transactions*, strony 765–785, 1972.
- [38] S. Standard, *Driver hand control reach - SAE J287*, 1976.
- [39] S. Standard, *Direction-of-motion stereotypes for automotive hand controls - J1139*, 1977.
- [40] S. Standard, *Symbols for motor vehicle controls - J1048*, 1974.
- [41] „Mechanical vibration and shock—guide for the evaluation of human exposure to whole-body vibration,” International Organization for Standardization, Geneva, CH, Standard, 1974.
- [42] N. H. T. S. Administration. „Vehicle Crash Test Database: Test Number 14391,” U.S. Department of Transportation. (2022), adres: <https://www.nhtsa.gov/research-data/research-testing-databases#/vehicle/14391>.
- [43] H. Bubb, F. Engstler, F. Fritzsche i inni, „The development of RAMSIS in past and future as an example for the cooperation between industry and university,” *International Journal of Human Factors Modelling and Simulation*, tom 1, numer 1, strony 140–157, 2006.
- [44] P. Blanchonette, „Jack Human Modelling Tool: A Review.,” 2010.
- [45] T. Dingus, L. Hardee i W. Wierwille, „Detection of drowsy and intoxicated drivers based on highway driving performance measures,” *IEOR Department Report*, tom 8402, 1985.
- [46] W. W. Wierwille, M. C. Hulse, T. J. Fischer i T. A. Dingus, „Strategic use of visual resources by the driver while navigating with an in-car navigation display system,” SAE Technical Paper, sprawozdanie techniczne, 1988.
- [47] C. Heinrich i N. Stanton, „Automotive HMI international standards,” w *Advances in Human Aspects of Road and Rail Transportation*, CRC Press, 2012, strony 605–614.
- [48] I. O. of Standardization., *Road Vehicles—Ergonomic Aspects of Transport Information and Control Systems—Dialogue Management Principles and Compliance Procedures*, 2002.
- [49] P. Green, „Estimating compliance with the 15-second rule for driver-interface usability and safety,” w *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, SAGE Publications Sage CA: Los Angeles, CA, tom 43, 1999, strony 987–991.

- [50] W. Prestl, T. Sauer, J. Steinle i O. Tschernoster, „The BMW active cruise control ACC,” SAE Technical paper, sprawozdanie techniczne, 2000.
- [51] F. Gustafsson, „Automotive safety systems,” *IEEE Signal Processing Magazine*, tom 26, numer 4, strony 32–47, 2009. DOI: 10.1109/MSP.2009.932618.
- [52] D. Linzmeier, „Pedestrian detection with thermopiles using an occupancy grid,” w *Proceedings. The 7th International IEEE Conference on Intelligent Transportation Systems (IEEE Cat. No.04TH8749)*, 2004, strony 1063–1068. DOI: 10.1109/ITSC.2004.1399054.
- [53] K. Fuerstenberg, K. Dietmayer i V. Willhoeft, „Pedestrian recognition in urban traffic using a vehicle based multilayer laserscanner,” w *Intelligent Vehicle Symposium, 2002. IEEE*, tom 1, 2002, 31–35 vol.1. DOI: 10.1109/IVS.2002.1187923.
- [54] H. Guo, D. Cao, H. Chen, C. Lv, H. Wang i S. Yang, „Vehicle dynamic state estimation: state of the art schemes and perspectives,” *IEEE/CAA Journal of Automatica Sinica*, tom 5, numer 2, strony 418–431, 2018. DOI: 10.1109/JAS.2017.7510811.
- [55] H.-J. Cho i M.-T. Tseng, „A support vector machine approach to CMOS-based radar signal processing for vehicle classification and speed estimation,” *Mathematical and Computer Modelling*, tom 58, numer 1, strony 438–448, 2013, Financial IT & Security and 2010 International Symposium on Computational Electronics. DOI: <https://doi.org/10.1016/j.mcm.2012.11.003>.
- [56] C. Blanc, R. Aufrère, L. Malaterre, J. Gallice i J. Alizon, „Obstacle detection and tracking by millimeter wave RADAR,” *IFAC Proceedings Volumes*, tom 37, numer 8, strony 322–327, 2004, IFAC/EURON Symposium on Intelligent Autonomous Vehicles, Lisbon, Portugal, 5-7 July 2004. DOI: [https://doi.org/10.1016/S1474-6670\(17\)31996-1](https://doi.org/10.1016/S1474-6670(17)31996-1).
- [57] X. Sun, Z. Zhou, C. Zhao i W. Zou, „A compressed sensing radar detection scheme for closing vehicle detection,” w *2012 IEEE International Conference on Communications (ICC)*, 2012, strony 6371–6375. DOI: 10.1109/ICC.2012.6364925.
- [58] F. Nashashibi i A. Bargeton, „Laser-based vehicles tracking and classification using occlusion reasoning and confidence estimation,” w *2008 IEEE Intelligent Vehicles Symposium*, 2008, strony 847–852. DOI: 10.1109/IVS.2008.4621244.
- [59] D. J. Natale, R. L. Tutwiler, M. S. Baran i J. R. Durkin, „Using full motion 3D Flash LIDAR video for target detection, segmentation, and tracking,” w *2010 IEEE Southwest Symposium on Image Analysis & Interpretation (SSIAI)*, 2010, strony 21–24. DOI: 10.1109/SSIAI.2010.5483929.
- [60] Y. Zeng, H. Yu, H. Dai i inni, „An Improved Calibration Method for a Rotating 2D LIDAR System,” *Sensors*, tom 18, numer 2, 2018. DOI: 10.3390/s18020497.
- [61] J. Kim, S. Hong, J. Baek, E. Kim i H. Lee, „Autonomous vehicle detection system using visible and infrared camera,” w *2012 12th International Conference on Control, Automation and Systems*, 2012, strony 630–634.

- [62] C.-C. R. Wang i J.-J. J. Lien, „Automatic Vehicle Detection Using Local Features—A Statistical Approach,” *IEEE Transactions on Intelligent Transportation Systems*, tom 9, numer 1, strony 83–96, 2008. DOI: 10.1109/TITS.2007.908572.
- [63] M. van Leeuwen i F. Groen, „Vehicle detection with a mobile camera: spotting midrange, distant, and passing cars,” *IEEE Robotics & Automation Magazine*, tom 12, numer 1, strony 37–43, 2005. DOI: 10.1109/MRA.2005.1411417.
- [64] S.-S. Ieng, J. Vrignon, D. Gruyer i D. Aubert, „A new multi-lanes detection using multi-camera for robust vehicle location,” w *IEEE Proceedings. Intelligent Vehicles Symposium, 2005.*, 2005, strony 700–705. DOI: 10.1109/IVS.2005.1505185.
- [65] U. Kadow, G. Schneider i A. Vukotich, „Radar-Vision Based Vehicle Recognition with Evolutionary Optimized and Boosted Features,” w *2007 IEEE Intelligent Vehicles Symposium, 2007*, strony 749–754. DOI: 10.1109/IVS.2007.4290206.
- [66] R. Velazquez-Pupo, A. Sierra-Romero, D. Torres-Roman i inni, „Vehicle Detection with Occlusion Handling, Tracking, and OC-SVM Classification: A High Performance Vision-Based System,” *Sensors*, tom 18, numer 2, 2018. DOI: 10.3390/s18020374.
- [67] M. Q. Khan i S. Lee, „A Comprehensive Survey of Driving Monitoring and Assistance Systems,” *Sensors*, tom 19, numer 11, 2019. DOI: 10.3390/s19112574.
- [68] M. Sidikova, R. Martinek, A. Kawala-Sterniuk i inni, „Vital Sign Monitoring in Car Seats Based on Electrocardiography, Ballistocardiography and Seismocardiography: A Review,” *Sensors*, tom 20, numer 19, 2020. DOI: 10.3390/s20195699. adres: <https://www.mdpi.com/1424-8220/20/19/5699>.
- [69] R. Adla, N. Al-Holou, M. Murad i Y. A. Bazzi, „Automotive collision avoidance methodologies Sensor-based and ITS-based,” w *2013 ACS International Conference on Computer Systems and Applications (AICCSA)*, 2013, strony 1–8. DOI: 10.1109/AICCSA.2013.6616458.
- [70] Y. P. Fallah, C. Huang, R. Sengupta i H. Krishnan, „Design of Cooperative Vehicle Safety Systems Based on Tight Coupling of Communication, Computing and Physical Vehicle Dynamics,” w *Proceedings of the 1st ACM/IEEE International Conference on Cyber-Physical Systems*, seria IC-CPS '10, Stockholm, Sweden: Association for Computing Machinery, 2010, strony 159–167. DOI: 10.1145/1795194.1795217.
- [71] P. Lytrivis i A. Amditis, „Intelligent transport systems: Co-operative systems (vehicular communications),” *Wireless Communications and Networks-Recent Advances*, 2012.
- [72] P. Lytrivis, G. Thomaidis i A. Amditis, „Sensor Data Fusion in Automotive Applications,” w *Sensor and Data Fusion*, N. Milisavljevic, redaktor, Rijeka: IntechOpen, 2009, rozdział 7. DOI: 10.5772/6574.
- [73] Y. L. Morgan, „Notes on DSRC & WAVE Standards Suite: Its Architecture, Design, and Characteristics,” *IEEE Communications Surveys & Tutorials*, tom 12, numer 4, strony 504–518, 2010. DOI: 10.1109/SURV.2010.033010.00024.

- [74] D. Macii, A. Boni, M. D. Cecco i D. Petri, „Tutorial 14: multisensor data fusion,” *IEEE Instrumentation & Measurement Magazine*, tom 11, numer 3, strony 24–33, 2008. DOI: 10.1109/MIM.2008.4534375.
- [75] K. Laberteaux i H. Hartenstein, *VANET: vehicular applications and inter-networking technologies*. John Wiley & Sons, 2009.
- [76] C.-M. Huang i S.-Y. Lin, „An early collision warning algorithm for vehicles based on V2V communication,” *International Journal of Communication Systems*, tom 25, numer 6, strony 779–795, 2012.
- [77] R. Sengupta, S. Rezaei, S. E. Shladover, D. Cody, S. Dickey i H. Krishnan, „Cooperative Collision Warning Systems: Concept Definition and Experimental Implementation,” *Journal of Intelligent Transportation Systems*, tom 11, numer 3, strony 143–155, 2007. DOI: 10.1080/15472450701410452.
- [78] S. Rezaei, R. Sengupta i H. Krishnan, „Reducing the Communication Required By DSRC-Based Vehicle Safety Systems,” w *2007 IEEE Intelligent Transportation Systems Conference*, 2007, strony 361–366. DOI: 10.1109/ITSC.2007.4357633.
- [79] S. Rezaei, R. Sengupta, H. Krishnan, X. Guan i R. Bhatia, „Tracking the position of neighboring vehicles using wireless communications,” *Transportation Research Part C: Emerging Technologies*, tom 18, numer 3, strony 335–350, 2010, 11th IFAC Symposium: The Role of Control. DOI: <https://doi.org/10.1016/j.trc.2009.05.010>.
- [80] C. Stiller, F. Puente León i M. Kruse, „Information fusion for automotive applications – An overview,” *Information Fusion*, tom 12, numer 4, strony 244–252, 2011, Special Issue on Information Fusion for Cognitive Automobiles. DOI: <https://doi.org/10.1016/j.inffus.2011.03.005>.
- [81] F. Ahlers i C. Stimming, „Cooperative Laserscanner Pre-Data-Fusion,” w *2008 IEEE Intelligent Vehicles Symposium*, 2008, strony 1187–1190. DOI: 10.1109/IVS.2008.4621194.
- [82] P. Lytrivis, G. Thomaidis i A. Amditis, „Cooperative Path Prediction in Vehicular Environments,” w *2008 11th International IEEE Conference on Intelligent Transportation Systems*, 2008, strony 803–808. DOI: 10.1109/ITSC.2008.4732629.
- [83] W. Huang, K. Wang, Y. Lv i F. Zhu, „Autonomous vehicles testing methods review,” w *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, IEEE, 2016, strony 163–168.
- [84] P. Sauras-Perez, A. Gil, J. S. Gill, P. Pisu i J. Taiber, „Voge: A voice and gesture system for interacting with autonomous cars,” SAE Technical Paper, sprawozdanie techniczne, 2017.
- [85] T. B. Sheridan, W. L. Verplank i T. Brooks, „Human/computer control of undersea teleoperators,” w *NASA Ames Res. Center The 14th Ann. Conf. on Manual Control*, 1978.

- [86] R. Parasuraman, T. B. Sheridan i C. D. Wickens, „A model for types and levels of human interaction with automation,” *IEEE Transactions on systems, man, and cybernetics-Part A: Systems and Humans*, tom 30, numer 3, strony 286–297, 2000.
- [87] M. Bonner, R. Taylor, K. Fletcher i C. Miller, „Adaptive automation and decision aiding in the military fast jet domain,” *Proceedings of Human Performance, Situation Awareness, and Automation*, strony 154–159, 2000.
- [88] R. M. Taylor, „Capability, cognition and autonomy,” w *Proceedings of RTO Human Factors and Medicine Panel (HFM) Symposium*, 2002.
- [89] D. Richards i A. Stedmon, „To delegate or not to delegate: A review of control frameworks for autonomous cars,” *Applied ergonomics*, tom 53, strony 383–388, 2016.
- [90] F. M. Favarò, N. Nader, S. O. Eurich, M. Tripp i N. Varadaraju, „Examining accident reports involving autonomous vehicles in California,” *PLoS one*, tom 12, numer 9, e0184952, 2017.
- [91] „Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles,” SAE International, Standard, 2021. DOI: [doi.org/10.4271/J3016\\_202104](https://doi.org/10.4271/J3016_202104).
- [92] D. Paddeu, I. Shergold i G. Parkhurst, „The social perspective on policy towards local shared autonomous vehicle services (LSAVS),” *Transport Policy*, tom 98, strony 116–126, 2020.
- [93] M. Garavello, P. Goatin, T. Liard i B. Piccoli, „A multiscale model for traffic regulation via autonomous vehicles,” *Journal of Differential Equations*, tom 269, numer 7, strony 6088–6124, 2020.
- [94] N. H. T. S. Administration i inni, *United State Department of Transportation*, „Automated vehicles for safety”.
- [95] J. Wang, L. Zhang, Y. Huang, J. Zhao i F. Bella, „Safety of autonomous vehicles,” *Journal of advanced transportation*, tom 2020, strony 1–13, 2020.
- [96] H. Vdovic, J. Babic i V. Podobnik, „Automotive software in connected and autonomous electric vehicles: A review,” *IEEE Access*, tom 7, strony 166 365–166 379, 2019.
- [97] K. Jo, J. Kim, D. Kim, C. Jang i M. Sunwoo, „Development of autonomous car—Part I: Distributed system architecture and development process,” *IEEE Transactions on Industrial Electronics*, tom 61, numer 12, strony 7131–7140, 2014.
- [98] A. Borowsky i T. Oron-Gilad, „The effects of automation failure and secondary task on drivers’ ability to mitigate hazards in highly or semi-automated vehicles.,” *Advances in Transportation Studies*, numer 1, 2016.
- [99] U. Ozguner, C. Stiller i K. Redmill, „Systems for safety and autonomous behavior in cars: The DARPA Grand Challenge experience,” *Proceedings of the IEEE*, tom 95, numer 2, strony 397–412, 2007.
- [100] D. González, J. Pérez, V. Milanés i F. Nashashibi, „A review of motion planning techniques for automated vehicles,” *IEEE Transactions on intelligent transportation systems*, tom 17, numer 4, strony 1135–1145, 2015.

- [101] H. Zhang, C. J. Sheppard, T. E. Lipman, T. Zeng i S. J. Moura, „Charging infrastructure demands of shared-use autonomous electric vehicles in urban areas,” *Transportation Research Part D: Transport and Environment*, tom 78, strona 102 210, 2020.
- [102] A. Sarmiento, B. Garcia, L. Coriteac i L. Navarenho, „The autonomous vehicle challenges for emergent market,” SAE Technical Paper, sprawozdanie techniczne, 2017.
- [103] J. Yang, T. Chen, B. Payne, P. Guo, Y. Zhang i J. Guo, „Generating routes for autonomous driving in vehicle-to-infrastructure communications,” *Digital Communications and Networks*, tom 6, numer 4, strony 444–451, 2020.
- [104] M. Gerla, E.-K. Lee, G. Pau i U. Lee, „Internet of vehicles: From intelligent grid to autonomous cars and vehicular clouds,” w *2014 IEEE world forum on internet of things (WF-IoT)*, IEEE, 2014, strony 241–246.
- [105] A. de la Escalera, L. Moreno, M. Salichs i J. Armingol, „Road traffic sign detection and classification,” *IEEE Transactions on Industrial Electronics*, tom 44, numer 6, strony 848–859, 1997. DOI: 10.1109/41.649946.
- [106] T. Suwattanapunkul i L.-J. Wang, „The Efficient Traffic Sign Detection and Recognition for Taiwan Road Using YOLO Model with Hybrid Dataset,” w *2023 9th International Conference on Applied System Innovation (ICASI)*, 2023, strony 160–162. DOI: 10.1109/ICASI57738.2023.10179493.
- [107] K. Jo, J. Kim, D. Kim, C. Jang i M. Sunwoo, „Development of autonomous car—Part II: A case study on the implementation of an autonomous driving system based on distributed architecture,” *IEEE Transactions on Industrial Electronics*, tom 62, numer 8, strony 5119–5132, 2015.
- [108] C. Ilas, „Electronic sensing technologies for autonomous ground vehicles: A review,” w *2013 8th International Symposium on Advanced Topics in Electrical Engineering (ATEE)*, IEEE, 2013, strony 1–6.
- [109] T. Ha, S. Kim, D. Seo i S. Lee, „Effects of explanation types and perceived risk on trust in autonomous vehicles,” *Transportation research part F: traffic psychology and behaviour*, tom 73, strony 271–280, 2020.
- [110] S. Yu, J. Puchinger i S. Sun, „Two-echelon urban deliveries using autonomous vehicles,” *Transportation Research Part E: Logistics and Transportation Review*, tom 141, strona 102 018, 2020.
- [111] Y. Liu i A. B. Whinston, „Efficient real-time routing for autonomous vehicles through bayes correlated equilibrium: An information design framework,” *Information Economics and Policy*, tom 47, strony 14–26, 2019.
- [112] C. Ryan, F. Murphy i M. Mullins, „Spatial risk modelling of behavioural hotspots: Risk-aware path planning for autonomous vehicles,” *Transportation research part A: policy and practice*, tom 134, strony 152–163, 2020.
- [113] P. Lin, „Why ethics matters for autonomous cars,” *Autonomous driving: Technical, legal and social aspects*, strony 69–85, 2016.

- [114] C. Wilwert, N. Navet, F. Simonot-Lion i inni, *Design of automotive X-by-Wire systems*, 2005.
- [115] M. Lukasiewicz, S. Steinhorst, S. Andalám i inni, „System architecture and software design for electric vehicles,” w *Proceedings of the 50th Annual Design Automation Conference*, 2013, strony 1–6.
- [116] K. Wang, G. Li, J. Chen i inni, „The adaptability and challenges of autonomous vehicles to pedestrians in urban China,” *Accident Analysis & Prevention*, tom 145, strona 105–119, 2020.
- [117] S. C. Stanciu, D. W. Eby, L. J. Molnar, R. M. St. Louis, N. Zanier i L. P. Kostyniuk, „Pedestrians/bicyclists and autonomous vehicles: how will they communicate?” *Transportation research record*, tom 2672, numer 22, strony 58–66, 2018.
- [118] O. T. Ritchie, D. G. Watson, N. Griffiths i inni, „How should autonomous vehicles overtake other drivers?” *Transportation research part F: traffic psychology and behaviour*, tom 66, strony 406–418, 2019.
- [119] J. D. Rupp i A. G. King, „Autonomous Driving — A Practical Roadmap,” *SAE International*, 2010.
- [120] A. Eriksson i N. A. Stanton, „Takeover time in highly automated vehicles: noncritical transitions to and from manual control,” *Human factors*, tom 59, numer 4, strony 689–705, 2017.
- [121] L. J. Molnar, L. H. Ryan, A. K. Pradhan, D. W. Eby, R. M. S. Louis i J. S. Zakrajsek, „Understanding trust and acceptance of automated vehicles: An exploratory simulator study of transfer of control between automated and manual driving,” *Transportation research part F: traffic psychology and behaviour*, tom 58, strony 319–328, 2018.
- [122] A. Eriksson i N. A. Stanton, „Driving performance after self-regulated control transitions in highly automated vehicles,” *Human factors*, tom 59, numer 8, strony 1233–1248, 2017.
- [123] A. Calvi, F. D’Amico, C. Ferrante i L. B. Ciampoli, „A driving simulator study to assess driver performance during a car-following maneuver after switching from automated control to manual control,” *Transportation research part F: traffic psychology and behaviour*, tom 70, strony 58–67, 2020.
- [124] M. Cunningham i M. A. Regan, „Autonomous vehicles: human factors issues and future research,” w *Proceedings of the 2015 Australasian Road safety conference*, tom 14, 2015.
- [125] D. Fényes, B. Németh i P. Gáspár, „A predictive control for autonomous vehicles using big data analysis,” *IFAC-PapersOnLine*, tom 52, numer 5, strony 191–196, 2019.
- [126] S. Lee, Y. Kim, H. Kahng i inni, „Intelligent traffic control for autonomous vehicle systems based on machine learning,” *Expert Systems with Applications*, tom 144, strona 113–124, 2020.
- [127] Q. Chen, M. Lin, B. Dai i J. Chen, „Typical pedestrian accident scenarios in China and crash severity mitigation by autonomous emergency braking systems,” SAE Technical Paper, sprawozdanie techniczne, 2015.
- [128] S. Imhof, J. Frölicher i W. von Arx, „Shared Autonomous Vehicles in rural public transportation systems,” *Research in transportation economics*, tom 83, strona 100–112, 2020.

- [129] F. Liu, F. Zhao, Z. Liu i H. Hao, „Can autonomous vehicle reduce greenhouse gas emissions? A country-level evaluation,” *Energy Policy*, tom 132, strony 462–473, 2019.
- [130] S. Rafael, L. P. Correia, D. Lopes i inni, „Autonomous vehicles opportunities for cities air quality,” *Science of the Total Environment*, tom 712, strona 136 546, 2020.
- [131] M. A. Figliozzi, „Carbon emissions reductions in last mile and grocery deliveries utilizing air and ground autonomous vehicles,” *Transportation Research Part D: Transport and Environment*, tom 85, strona 102 443, 2020.
- [132] A. Calvi, F. D’Amico, L. B. Ciampoli i C. Ferrante, „Evaluation of driving performance after a transition from automated to manual control: a driving simulator study,” *Transportation research procedia*, tom 45, strony 755–762, 2020.
- [133] R. E. Stern, S. Cui, M. L. Delle Monache i inni, „Dissipation of stop-and-go waves via control of autonomous vehicles: Field experiments,” *Transportation Research Part C: Emerging Technologies*, tom 89, strony 205–221, 2018.
- [134] I. Rasheed, F. Hu i L. Zhang, „Deep reinforcement learning approach for autonomous vehicle systems for maintaining security and safety using LSTM-GAN,” *Vehicular Communications*, tom 26, strona 100 266, 2020.
- [135] Đ. Petrović, R. Mijailović i D. Pešić, „Traffic accidents with autonomous vehicles: type of collisions, manoeuvres and errors of conventional vehicles’ drivers,” *Transportation research procedia*, tom 45, strony 161–168, 2020.
- [136] „Risk-based autonomous vehicle motion control with considering human driver’s behaviour,” *Transportation Research Part C: Emerging Technologies*, tom 107, strony 1–14, 2019. DOI: <https://doi.org/10.1016/j.trc.2019.08.003>.
- [137] L. Zhang, F. Chen, X. Ma, X. Pan i inni, „Fuel economy in truck platooning: A literature overview and directions for future research,” *Journal of Advanced Transportation*, tom 2020, 2020.
- [138] S. Chen, H. Wang i Q. Meng, „Designing autonomous vehicle incentive program with uncertain vehicle purchase price,” *Transportation Research Part C: Emerging Technologies*, tom 103, strony 226–245, 2019.
- [139] F. Nazari, M. Noruzoliaee i A. K. Mohammadian, „Shared versus private mobility: Modeling public interest in autonomous vehicles accounting for latent attitudes,” *Transportation Research Part C: Emerging Technologies*, tom 97, strony 456–477, 2018.
- [140] C. J. Haboucha, R. Ishaq i Y. Shiftan, „User preferences regarding autonomous vehicles,” *Transportation Research Part C: Emerging Technologies*, tom 78, strony 37–49, 2017.
- [141] K. F. Yuen, Y. D. Wong, F. Ma i X. Wang, „The determinants of public acceptance of autonomous vehicles: An innovation diffusion perspective,” *Journal of Cleaner Production*, tom 270, strona 121 904, 2020.

- [142] H. Zhong, W. Li, M. W. Burris, A. Talebpour i K. C. Sinha, „Will autonomous vehicles change auto commuters’ value of travel time?” *Transportation Research Part D: Transport and Environment*, tom 83, strona 102–303, 2020.
- [143] K. Hilgarter i P. Granig, „Public perception of autonomous vehicles: A qualitative study based on interviews after riding an autonomous shuttle,” *Transportation research part F: traffic psychology and behaviour*, tom 72, strony 226–243, 2020.
- [144] S. Wang, Z. Jiang, R. B. Noland i A. S. Mondschein, „Attitudes towards privately-owned and shared autonomous vehicles,” *Transportation research part F: traffic psychology and behaviour*, tom 72, strony 297–306, 2020.
- [145] R. Adla, N. Al-Holou, M. Murad i Y. A. Bazzi, „Automotive collision avoidance methodologies Sensor-based and ITS-based,” w *2013 ACS International Conference on Computer Systems and Applications (AICCSA)*, 2013, strony 1–8. DOI: 10.1109/AICCSA.2013.6616458.
- [146] D. L. Hall i J. Llinas, „An introduction to multisensor data fusion,” *Proceedings of the IEEE*, tom 85, numer 1, strony 6–23, 1997.
- [147] H.-M. Wang, H.-Y. Lin i C.-C. Chang, „Object Detection and Depth Estimation Approach Based on Deep Convolutional Neural Networks,” *Sensors*, tom 21, numer 14, 2021. DOI: 10.3390/s21144755. adres: <https://www.mdpi.com/1424-8220/21/14/4755>.
- [148] B. Khaleghi, A. Khamis, F. O. Karray i S. N. Razavi, „Multisensor data fusion: A review of the state-of-the-art,” *Information fusion*, tom 14, numer 1, strony 28–44, 2013.
- [149] P. Lytrivis, G. Thomaidis i A. Amditis, „Sensor Data Fusion in Automotive Applications,” w *Sensor and Data Fusion*, N. Milisavljevic, redaktor, Rijeka: IntechOpen, 2009, rozdział 7. DOI: 10.5772/6574. adres: <https://doi.org/10.5772/6574>.
- [150] Y. Bar-Shalom, P. K. Willett i X. Tian, *Tracking and data fusion*. YBS publishing Storrs, CT, USA: 2011.
- [151] X. Yuan, F. Lian i C. Han, „Models and algorithms for tracking target with coordinated turn motion,” *Mathematical Problems in Engineering*, tom 2014, numer 1, strona 649–276, 2014.
- [152] C. Waldschmidt, J. Hasch i W. Menzel, „Automotive radar—From first efforts to future systems,” *IEEE Journal of Microwaves*, tom 1, numer 1, strony 135–148, 2021.
- [153] M. Camiade, D. Domnesque, P. Alleaume, A. Mallet, D. Pons i H. Dambkes, „Full MMIC millimeter-wave front end for a 76.5 GHz adaptive cruise control car radar,” w *1999 IEEE MTT-S International Microwave Symposium Digest (Cat. No.99CH36282)*, tom 4, 1999, 1489–1492 vol.4. DOI: 10.1109/MWSYM.1999.780234.
- [154] H. P. Forstner, F. Starzer, G. Haider, C. Wagner i M. Jahn, „Frequency quadruplers for a 77GHz subharmonically pumped automotive radar transceiver in SiGe,” w *2009 European Microwave Integrated Circuits Conference (EuMIC)*, 2009, strony 188–191.

- [155] U. Chipengo, P. M. Krenz i S. Carpenter, „From antenna design to high fidelity, full physics automotive radar sensor corner case simulation,” *Modelling and Simulation in Engineering*, tom 2018, numer 1, strona 4 239 725, 2018.
- [156] G. Hakobyan i B. Yang, „High-performance automotive radar: A review of signal processing algorithms and modulation schemes,” *IEEE Signal Processing Magazine*, tom 36, numer 5, strony 32–44, 2019.
- [157] F. Engels, P. Heidenreich, M. Wintermantel, L. Stäcker, M. Al Kadi i A. M. Zoubir, „Automotive radar signal processing: Research directions and practical challenges,” *IEEE Journal of Selected Topics in Signal Processing*, tom 15, numer 4, strony 865–878, 2021.
- [158] W. Zieniutycz, *Anteny o sterowanej wiązce w technice radarowej*. Warszawa: Wydawnictwa Komunikacji i Łączności, 2012.
- [159] S. Rao. „MIMO Radar,” Texas Instruments. (lip. 2018), adres: <https://www.ti.com/lit/an/swra554a/swra554a.pdf> (termin wizyty 13.07.2024).
- [160] B. Vogginger, F. Kreutz, J. López-Randulfe i inni, „Automotive radar processing with spiking neural networks: Concepts and challenges,” *Frontiers in neuroscience*, tom 16, strona 851 774, 2022.
- [161] J. Kusiak, A. Danielewska-Tulecka i P. Oprocha, *Optymalizacja: wybrane metody z przykładami zastosowań*. Wydawnictwo Naukowe PWN SA, 2022.
- [162] C. T. Kelley, *Iterative methods for optimization*. SIAM, 1999.
- [163] M. Locatelli i F. Schoen, *Global optimization: theory, algorithms, and applications*. SIAM, 2013.
- [164] I. Markovsky i S. Van Huffel, „Overview of total least-squares methods,” *Signal processing*, tom 87, numer 10, strony 2283–2302, 2007.
- [165] M. Murad, I. Bilik, M. Friesen i inni, „Requirements for next generation automotive radars,” w *2013 IEEE Radar Conference (RadarCon13)*, kw. 2013, strony 1–6.
- [166] Y. Li, W. Liu, Q. Liu, X. Zheng, K. Sun i C. Huang, „Complying with ISO 26262 and ISO/SAE 21434: A Safety and Security Co-Analysis Method for Intelligent Connected Vehicle,” *Sensors*, tom 24, strona 1848, 6 2024.
- [167] R. Pinnock, *Radar apparatus for a vehicle and method of detecting misalignment*, US Patent App. 17/046,862, lip. 2021.
- [168] F. A. Ibrahim i G. L. Sielagoski, *Method for correcting radar misalignment*, US Patent 6,714,156, lip. 2004.
- [169] H. S. Ham, *Alignment system and method for radar apparatus*, US Patent 8,973,278, lip. 2015.
- [170] M. A. Aleem, B. Fath i S. H. Gaboury, *Bumper integrated forward radar mounting system*, US Patent 8,833,815, lip. 2014.
- [171] J. A. Hartley, P. Schmitt, J. V. B. III i inni, *Vehicle mounting and alignment bracket*, US Patent 7,988,212, lip. 2011.
- [172] S. H. Gaboury, *Tilt sensing system for automotive radar*, US Patent App. 13/325,085, lip. 2013.

- [173] J. Bai, M. Nakamura, K. Hanawa, T. Monji, K. Takano i N. Sato, *Car on-board radar axis adjusting method*, US Patent 6,020,844, lip. 2000.
- [174] R. Abou-Jaoude, „ACC radar sensor technology, test requirements, and test solutions,” *IEEE Transactions on Intelligent Transportation Systems*, tom 4, strony 115–122, 3 2003.
- [175] T. R. Jones i T. L. Gasparovic, *Vehicle radar alignment method and system*, US Patent 9,182,477, lip. 2015.
- [176] H. A. H. Wodrich, H. Hess, S. Pliefke i W. G. Woodington, *Vehicular radar system with automatic sensor alignment*, US Patent 11,333,739, lip. 2022.
- [177] M. Z. Ikram i A. Ahmad, „Automated Radar Mount-Angle Calibration in Automotive Applications,” w *2019 IEEE Radar Conference (RadarConf)*, wrz. 2019, strony 1–5.
- [178] M. Slutsky, D. I. Dobkin, S. Villevall i I. Bilik, *Three-dimensional alignment of radar and camera sensors*, US Patent App. 15/788,048, lip. 2019.
- [179] P. R. Haney, M. J. Richardson i E. G. Hoare, *Automotive radar elevation alignment*, US Patent 6,778,131, lip. 2004.
- [180] R. Hellinger i O. F. Schwindt, *Automotive radar alignment*, US Patent 10,585,170, lip. 2020.
- [181] M. I. Grace, *Automobile radar antenna alignment system using transponder and lasers*, US Patent 6,329,952, lip. 2001.
- [182] M. I. Grace i D. A. Bradley, *Universal autoradar antenna alignment system*, US Patent 6,087,995, lip. 2000.
- [183] M. Grace, R. Abou-Jaoude, K. Noujeim i D. Bradley, „76GHz Radar Antenna Alignment System,” w *2000 30th European Microwave Conference*, paź. 2000, strony 1–4.
- [184] O. Isaji, *Method and device for aligning radar mount direction, and radar aligned by the method or device*, US Patent 6,933,883, lip. 2005.
- [185] J. F. Searcy, D. L. Hart i S. W. Alland, *Method of measuring elevational mis-alignment of an automotive radar sensor*, US Patent 6,556,166, lip. 2003.
- [186] R. Borruso, *Radar sensor alignment*, US Patent 8,830,119, lip. 2014.
- [187] D. A. Preston i D. N. Olmstead, *System and method for aligning sensors on a vehicle*, US Patent 7,337,650, lip. 2008.
- [188] B. Demersseman i K. Lee, *Sensing misalignment detection and estimation system*, US Patent 7,813,851, lip. 2010.
- [189] A. L. Mills i S. H. Gaboury, *Internal multi-axis G sensing used to align an automotive forward radar to the vehicle’s thrust axis*, US Patent 8,957,807, lip. 2015.
- [190] D. Steinbuch i R. Schnabel, *Method and device for ascertaining and compensating for a misalignment angle of a radar sensor of a vehicle*, US Patent 9,366,751, lip. 2016.
- [191] B. K. Park, K. K. Im i H. C. Ahn, *Alignment method and system for radar of vehicle*, US Patent 9,523,769, lip. 2016.

- [192] Y. K. Ameen i P. A. Ryan, *Method and apparatus for calibrating azimuth boresight in a radar system*, US Patent 5,977,906, lip. 1999.
- [193] S. Y. Kim, *Radar alignment apparatus and method of controlling the same*, US Patent 10,215,844, lip. 2019.
- [194] K.-r. Choi, G.-h. Seo, J.-e. Lee, S.-h. Jeong i J.-n. Oh, „Automatic radar horizontal alignment scheme using stationary target on public road,” w *2013 European Microwave Conference*, paź. 2013, strony 1863–1866.
- [195] S. W. Alland i J. F. Searcy, *Automatic sensor azimuth alignment*, US Patent 5,964,822, lip. 1999.
- [196] R. E. Helmick i T. R. Rice, „Removal of alignment errors in an integrated system of two 3-D sensors,” *IEEE Transactions on Aerospace and Electronic Systems*, tom 29, strony 1333–1343, 4 1993.
- [197] Y. Bao, T. Mahler, A. Pieper, A. Schreiber i M. Schulze, „Motion Based Online Calibration for 4D Imaging Radar in Autonomous Driving Applications,” w *2020 German Microwave Conference (GeMiC)*, mar. 2020, strony 108–111.
- [198] A. Bobaru, C. Nafornta i V. C. Vesa, „Unsupervised Online Horizontal Misalignment Detection Algorithm for Automotive Radar,” w *2022 14th International Conference on Communications (COMM)*, grud. 2022, strony 1–5.
- [199] D. Kellner, M. Barjenbruch, K. Dietmayer, J. Klappstein i J. Dickmann, „Joint radar alignment and odometry calibration,” w *2015 18th International Conference on Information Fusion (Fusion)*, lip. 2015, strony 366–374.
- [200] J. Ru i C. Xu, *Apparatus and method for detecting alignment of sensor in an automotive detection system*, US Patent 10,732,262, lip. 2020.
- [201] C. Alcalde i D. H. Vu, *Automated vehicle radar system with self-calibration*, US Patent 11,237,248, lip. 2022.
- [202] T. Campbell i L. Smith, *Radar mounting estimation with unstructured data*, US Patent 10,191,144, lip. 2019.
- [203] S. Zeng, X. Zhang i X. F. Song, *Method of automatic sensor pose estimation*, US Patent 10,088,553, lip. 2018.
- [204] J. K. Schiffmann, Y. Liu, D. A. Schwartz i X. Zhu, *Automated vehicle radar system with auto-alignment for azimuth, elevation, and vehicle speed-scaling-error*, US Patent 10,114,106, lip. 2018.
- [205] J. Guo, S. Sun i K. Li, *Automatic Azimuth Alignment for Automotive Radar*, 2018.
- [206] A. Bobaru, C. Nafornta, G. Copacean i V. C. Vesa, „Unsupervised Online Vertical Misalignment Detection Algorithm for Automotive Radar,” w *2022 International Symposium on Electronics and Telecommunications (ISETC)*, list. 2022, strony 1–5.
- [207] K. Suzuki, C. Yamano, Y. Miyake i T. Kitamura, „Bias angle error self-correction for automotive applications using phased array radars installed behind bumpers,” w *2017 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)*, mar. 2017, strony 155–158.

- [208] X. Cong, Y. Han, W. Sheng, S. Guo i R. Zhang, „Spatio-Temporal Alignment and Trajectory Matching for Netted Radar Without Prior Spatial Information and Time Delay,” *IEEE Access*, tom 8, strony 126 965–126 976, 2020.
- [209] X. Cong, Y. Han, W. Sheng, S. Guo i H. Sun, „Range-Doppler domain spatial alignment for networked radars,” *EURASIP Journal on Advances in Signal Processing*, tom 2022, strony 1–25, 1 2022.
- [210] L. Chen, G. H. Wang i I. F. Progni, „Unified registration model for both stationary and mobile 3D radar alignment,” *Journal of Electrical and Computer Engineering*, tom 2014, strona 29, 2014.
- [211] L. A. Rosero i F. S. Osório, „Calibration and multi-sensor fusion for on-road obstacle detection,” w *2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR)*, list. 2017, strony 1–6.
- [212] L. L. Nagy, „Electromagnetic reflectivity characteristics of road surfaces,” *IEEE Transactions on Vehicular Technology*, tom 23, strony 117–124, 4 1974. DOI: 10.1109/T-VT.1974.23582.
- [213] K. Sarabandi, E. S. Li i A. Nashashibi, „Modeling and measurements of scattering from road surfaces at millimeter-wave frequencies,” *IEEE Transactions on Antennas and Propagation*, tom 45, strony 1679–1688, 11 1997. DOI: 10.1109/8.650080.
- [214] V. Kurz, H. Stuelzebach, F. Pfeiffer, C. van Driesten i E. Biebl, „Road Surface Characteristics for the Automotive 77GHz Band,” *Advances in Radio Science*, tom 19, strony 165–172, 2021. DOI: 10.5194/ars-19-165-2021. adres: <https://ars.copernicus.org/articles/19/165/2021/>.
- [215] J. L. Eaves, „Introduction to radar,” w *Principles of Modern Radar*. Chapman & Hall, 1987, strony 1–27.
- [216] K. Geary, J. S. Colburn, A. Bekaryan, S. Zeng, B. Litkouhi i M. Murad, „Automotive radar target characterization from 22 to 29 GHz and 76 to 81 GHz,” w *2013 IEEE Radar Conference (Radar-Con13)*, kw. 2013, strony 1–6.
- [217] J. D. Echard, E. E. Martin, D. L. Odom i H. G. Cox, *Discrimination Between Targets and Clutter by Radar*, 1981.
- [218] N. C. Currie, „Clutter Characteristics and Effects,” w *Principles of Modern Radar*. Springer US, 1987, strony 281–342.
- [219] N. C. Currie, F. B. Dyer i R. D. Hayes, *Radar Land Clutter Measurements at Frequencies of 9.5, 16, 35, and 95 GHz*, 1975.
- [220] D. K. Barton, „Land clutter models for radar design and analysis,” *Proceedings of the IEEE*, tom 73, strony 198–204, 2 1985.
- [221] M. S. Greco i S. Watts, „Radar Clutter Modeling and Analysis,” w *Academic Press Library in Signal Processing: Volume 2*, N. D. Sidiropoulos, F. Gini, R. Chellappa i S. Theodoridis, redaktorzy. Elsevier, 2014, tom 2, strony 513–594.

- [222] R. R. Boothe, *The Weibull distribution applied to the ground clutter backscatter coefficient*, 1969.
- [223] J. B. Billingsley, „Approaches to Clutter Modeling,” w *Low-angle Radar Land Clutter: Measurements and Empirical Models*. William Andrew Pub., 2002, strony 285–407.
- [224] I. Aziz, W.-C. Liao, H. Aliakbari i W. Simon, „Compact and Low Cost Linear Antenna Array for Millimeter Wave Automotive Radar Applications,” w *2020 14th European Conference on Antennas and Propagation (EuCAP)*, mar. 2020, strony 1–4.
- [225] S. Holzwarth, R. Kulke i J. Kassner, „Integrated stacked patch antenna array on LTCC material operating at 24 GHz [automotive radar applications],” w *IEEE Antennas and Propagation Society Symposium, 2004.*, tom 2, czer. 2004, 1583–1586 Vol.2.
- [226] K. Y. Kapusuz, A. V. Berghe, S. Lemey i H. Rogier, „Partially Filled Half-Mode Substrate Integrated Waveguide Leaky-Wave Antenna for 24 GHz Automotive Radar,” *IEEE Antennas and Wireless Propagation Letters*, tom 20, strony 33–37, 1 2021.
- [227] S. Beer, G. Adamiuk i T. Zwick, „Novel Antenna Concept for Compact Millimeter-Wave Automotive Radar Sensors,” *IEEE Antennas and Wireless Propagation Letters*, tom 8, strony 771–774, 2009.
- [228] U. Naeem, D. Zelenchuk, V. Fusco, M. Keaveney, M. O’Shea i J. Breslin, „Automotive RADAR Front-End with Added Target Estimation in Elevation Plane,” w *2019 IEEE International Symposium on Antennas and Propagation and USNC-URSI Radio Science Meeting*, lip. 2019, strony 937–938.
- [229] H. Nagaishi, A. Kuriyama, H. Kuroda i A. Kitayama, „Horn and Prism Antenna for Dual Range and Dual FOV Automotive Radar Using 77-GHz Band,” w *2018 18th International Symposium on Antenna Technology and Applied Electromagnetics (ANTEM)*, sierp. 2018, strony 1–2.
- [230] S. Yoo, Y. Milyakh, H. Kim, C. Hong i H. Choo, „Patch Array Antenna Using a Dual Coupled Feeding Structure for 79 GHz Automotive Radar Applications,” *IEEE Antennas and Wireless Propagation Letters*, tom 19, strony 676–679, 4 2020.
- [231] W. Zhang, N. Li, J. Yu i E. Kasper, „A Compact Single-Board Solution for Commercializing Cost-Effective 77 GHz Automotive Front Radar,” w *2020 IEEE Asia-Pacific Microwave Conference (APMC)*, list. 2020, strony 1098–1100.
- [232] A. Haderer, C. Wagner, R. Feger i A. Stelzer, „Lateral velocity estimation using an FMCW radar,” w *2009 European Radar Conference (EuRAD)*, wrz. 2009, strony 129–132.
- [233] D. Zoeke i A. Zirotf, „Scale-invariant multi-sensor velocity component estimation using certainty grids,” w *2013 European Radar Conference*, paź. 2013, strony 156–159.
- [234] F. Folster i H. Rohling, „Lateral velocity estimation based on automotive radar sensors,” w *2006 CIE International Conference on Radar*, paź. 2006, strony 1–4.
- [235] S. Lim, J. Jung, B.-h. Lee, J. Choi i S.-C. Kim, „Radar Sensor-Based Estimation of Vehicle Orientation for Autonomous Driving,” *IEEE Sensors Journal*, tom 22, strony 21 924–21 932, 22 2022.

- [236] F. Roos, D. Kellner, J. Dickmann i C. Waldschmidt, „Reliable Orientation Estimation of Vehicles in High-Resolution Radar Images,” *IEEE Transactions on Microwave Theory and Techniques*, tom 64, strony 2986–2993, 9 2016.
- [237] J. Schlichenmaier, N. Selvaraj, M. Stolz i C. Waldschmidt, „Template matching for radar-based orientation and position estimation in automotive scenarios,” w *2017 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)*, mar. 2017, strony 95–98.
- [238] J. Schlichenmaier, F. Roos, M. Kunert i C. Waldschmidt, „Adaptive clustering for contour estimation of vehicles for high-resolution radar,” w *2016 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)*, maj 2016, strony 1–4.
- [239] P. Cai, S. Wang, Y. Sun i M. Liu, „Probabilistic End-to-End Vehicle Navigation in Complex Dynamic Environments With Multimodal Sensor Fusion,” *IEEE Robotics and Automation Letters*, tom 5, strony 4218–4224, 3 2020.
- [240] D. Coelho i M. Oliveira, „A Review of End-to-End Autonomous Driving in Urban Environments,” *IEEE Access*, tom 10, strony 75 296–75 311, 2022.
- [241] D. Musicki i R. J. Evans, „Multiscan Multitarget Tracking in Clutter with Integrated Track Splitting Filter,” *IEEE Transactions on Aerospace and Electronic Systems*, tom 45, strony 1432–1447, 4 2009.
- [242] H. A. P. Blom i E. A. Bloem, „Combining IMM and JPDA for tracking multiple maneuvering targets in clutter,” w *Proceedings of the Fifth International Conference on Information Fusion. FUSION 2002. (IEEE Cat.No.02EX5997)*, tom 1, lip. 2002, 705–712 vol.1.
- [243] N. T. Pham, K. Leman, M. Wong i F. Gao, „Combining JPDA and particle filter for visual tracking,” w *2010 IEEE International Conference on Multimedia and Expo*, lip. 2010, strony 1044–1049.
- [244] R. B. Angle, R. L. Streit i M. Efe, „A Low Computational Complexity JPDA Filter With Superposition,” *IEEE Signal Processing Letters*, tom 28, strony 1031–1035, 2021.
- [245] X. Xue, S. Huang, N. Li i W. Zhong, „Resolvable cluster target tracking based on wavelet coefficients and JPDA,” w *2021 International Symposium on Computer Technology and Information Science (ISCTIS)*, czer. 2021, strony 330–336.
- [246] S. Yeom, „Efficient multi-target tracking with sub-event IMM-JPDA and one-point prime initialization,” w *2008 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems*, sierp. 2008, strony 451–456.
- [247] M. Hadzagic, H. Michalska i A. Jouan, „IMM-JVC and IMM-JPDA for closely maneuvering targets,” w *Conference Record of Thirty-Fifth Asilomar Conference on Signals, Systems and Computers (Cat.No.01CH37256)*, tom 2, list. 2001, 1278–1282 vol.2.
- [248] D. Musicki, „Track Score and Target Existence,” w *2006 9th International Conference on Information Fusion*, lip. 2006, strony 1–7.
- [249] P. Horridge i S. Maskell, „Searching for, initiating and tracking multiple targets using existence probabilities,” w *2009 12th International Conference on Information Fusion*, lip. 2009, strony 611–617.

- [250] D. Svensson, F. Govaers, M. Ulmke i W. Koch, „Target existence probability in the distributed Kalman filter,” w *2013 Workshop on Sensor Data Fusion: Trends, Solutions, Applications (SDF)*, paź. 2013, strony 1–5.
- [251] S.-H. Bae i K.-J. Yoon, „Robust Online Multiobject Tracking With Data Association and Track Management,” *IEEE Transactions on Image Processing*, tom 23, strony 2820–2833, 7 2014.
- [252] S. Memon, H. Son, S. Ahmed i A. A. Memon, „Track split smoothing for target tracking in clutter,” w *2017 Fifth International Conference on Aerospace Science & Engineering (ICASE)*, list. 2017, strony 1–4.
- [253] Y. Li, Y. Liu, Y. Wang, Y. Lin i W. Shen, „The Millimeter-Wave Radar SLAM Assisted by the RCS Feature of the Target and IMU,” *Sensors*, tom 20, 18 2020. DOI: 10.3390/s20185421. adres: <https://www.mdpi.com/1424-8220/20/18/5421>.
- [254] R. Zhang, L. Cheng, S. Wang i inni, „Integrated Sensing and Communication with Massive MIMO: A Unified Tensor Approach for Channel and Target Parameter Estimation,” *IEEE Transactions on Wireless Communications*, strona 1, 2024. DOI: 10.1109/TWC.2024.3351856.
- [255] J. Kwon i N. Kwak, „Human detection by Neural Networks using a low-cost short-range Doppler radar sensor,” w *2017 IEEE Radar Conference (RadarConf)*, 2017, strony 0755–0760. DOI: 10.1109/RADAR.2017.7944304.
- [256] J. Kwon, S. Lee i N. Kwak, „Radar Application of Deep Neural Networks for Recognizing Micro-Doppler Radar Signals by Human Walking and Background Noise,” w *2018 International Symposium on Antennas and Propagation (ISAP)*, 2018, strony 1–2.
- [257] A. Shaaban, W. Furtner, R. Weigel i F. Lurz, „Spiking Neural Networks for Gesture Recognition Using Time Domain Radar Data,” w *2022 19th European Radar Conference (EuRAD)*, 2022, strony 33–36. DOI: 10.23919/EuRAD54643.2022.9924727.
- [258] B. Dekker, S. Jacobs, A. Kossen, M. Kruithof, A. Huizing i M. Geurts, „Gesture recognition with a low power FMCW radar and a deep convolutional neural network,” w *2017 European Radar Conference (EURAD)*, 2017, strony 163–166. DOI: 10.23919/EURAD.2017.8249172.
- [259] A. Stroescu, L. Daniel, D. Phippen, M. Cherniakov i M. Gashinova, „Object Detection on Radar Imagery for Autonomous Driving Using Deep Neural Networks,” w *2020 17th European Radar Conference (EuRAD)*, 2021, strony 120–123. DOI: 10.1109/EuRAD48048.2021.00041.
- [260] K. Kaiser, J. Daugalas, J. López-Randulfe, A. Knoll, R. Weigel i F. Lurz, „Complex-Valued Neural Networks for Millimeter Wave FMCW-Radar Angle Estimations,” w *2022 19th European Radar Conference (EuRAD)*, 2022, strony 145–148. DOI: 10.23919/EuRAD54643.2022.9924767.
- [261] C. Bachmann, S. Musman i A. Schultz, „Classification of simulated radar imagery using lateral inhibition neural networks,” w *Neural Networks for Signal Processing II Proceedings of the 1992 IEEE Workshop*, 1992, strony 279–288. DOI: 10.1109/NNSP.1992.253685.

- [262] O. Schumann, M. Hahn, N. Scheiner i inni, „RadarScenes: A Real-World Radar Point Cloud Data Set for Automotive Applications,” w *2021 IEEE 24th International Conference on Information Fusion (FUSION)*, list. 2021, strony 1–8. DOI: 10.23919/FUSION49465.2021.9627037.
- [263] H. Caesar, V. Bankiti, A. H. Lang i inni, „nusenes: A multimodal dataset for autonomous driving,” w *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2020, strony 11 621–11 631.
- [264] D. Barnes, M. Gadd, P. Murcutt, P. Newman i I. Posner, „The Oxford Radar RobotCar Dataset: A Radar Extension to the Oxford RobotCar Dataset,” w *2020 IEEE International Conference on Robotics and Automation (ICRA)*, 2020, strony 6433–6438. DOI: 10.1109/ICRA40945.2020.9196884.
- [265] A. Ouaknine, A. Newson, J. Rebut, F. Tupin i P. Pérez, „CARRADA Dataset: Camera and Automotive Radar with Range- Angle- Doppler Annotations,” w *2020 25th International Conference on Pattern Recognition (ICPR)*, 2021, strony 5068–5075. DOI: 10.1109/ICPR48806.2021.9413181.
- [266] M. Sheeny, E. De Pellegrin, S. Mukherjee, A. Ahrabian, S. Wang i A. Wallace, „RADIATE: A Radar Dataset for Automotive Perception in Bad Weather,” w *2021 IEEE International Conference on Robotics and Automation (ICRA)*, 2021, strony 1–7. DOI: 10.1109/ICRA48506.2021.9562089.
- [267] L. Zheng, Z. Ma, X. Zhu i inni, „TJ4DRadSet: A 4D Radar Dataset for Autonomous Driving,” w *2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)*, 2022, strony 493–498. DOI: 10.1109/ITSC55140.2022.9922539.
- [268] A. Dosovitskiy, G. Ros, F. Codevilla, A. Lopez i V. Koltun, „CARLA: An open urban driving simulator,” w *Conference on robot learning*, PMLR, 2017, strony 1–16.