



**AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE**

**DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH**

**DYSCYPLINA AUTOMATYKA, ELEKTRONIKA, ELEKTROTECHNIKA I  
TECHNOLOGIE KOSMICZNE**

**AUTOREFERAT ROZPRAWY DOKTORSKIEJ**

---

*Adaptacja modelu matematycznego czujnika radarowego na potrzeby  
testów zaawansowanych systemów wspomagania kierowcy  
w środowiskach wirtualnej jazdy*

---

Autor: *mgr inż. Michał Jasiński*  
Promotor pracy: *dr hab. inż. Paweł Skruch, prof. AGH*  
Promotor pomocniczy: *dr inż. Mateusz Komorkiewicz*

Praca wykonana: *Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie  
Wydział Elektrotechniki, Automatyki, Informatyki  
i Inżynierii Biomedycznej  
Katedra Automatyki i Robotyki*

Kraków, 2024

## 1 Streszczenie

Zaawansowane systemy wspomagania kierowcy (ang. Advanced Driver Assistance Systems, ADAS) pełnią dziś kluczową rolę w kontekście zapewnienia bezpieczeństwa w ruchu drogowym. Systemy te analizują w czasie rzeczywistym najbliższe otoczenie samochodu, bazując na informacjach zwróconych przez czujniki zamocowane na tym pojeździe, by w razie wystąpienia realnego zagrożenia przejąć kontrolę nad maszyną. Jedną z najważniejszych aplikacji jest zaawansowany system hamowania awaryjnego (ang. Advanced Emergency Braking System, AEBS), która ma na celu uniknięcie potencjalnie groźnej w skutkach kolizji, na przykład w momencie utraty koncentracji przez kierowcę lub w warunkach ograniczonej przejrzystości powietrza. Układy takie jak AEBS oparte są w znacznej mierze na pomiarach z radarów samochodowych, które dla pojazdów widocznych z perspektywy sensora obliczają ich odległość od czujnika, prędkość względną oraz kąt w płaszczyźnie horyzontalnej pomiędzy obiektem a celownikiem radaru (ang. boresight).

Weryfikacja urządzeń klasy ADAS to niezwykle kluczowe zagadnienie. W szczególności przed wdrożeniem systemu do produkcji należy w rzetelny sposób ocenić jego działanie w krytycznych sytuacjach. W tym celu przeprowadza się szereg jazd weryfikacyjnych, w trakcie których gromadzi się dane z czujników zamontowanych na samochodzie testowym. Następnie, na podstawie informacji zebranych z sensorów, analizuje się decyzje podjęte przez układ typu ADAS w trakcie danej serii przejazdów. Zrealizowanie tego typu kampanii w całości na drogach publicznych to niesłychanie kosztowna operacja. Dlatego coraz częściej producenci samochodów decydują się wykonać część eksperymentów w symulatorach jazdy. Dzięki takiemu podejściu, określanemu mianem wirtualnej walidacji, możliwe jest nie tylko skrócenie procesu oceny, ale także zweryfikowanie systemu w sytuacjach, które w rzeczywistości nie byłyby możliwe do przetestowania ze względów bezpieczeństwa.

Wirtualna walidacja musi być oczywiście wiarygodna, dlatego konieczne jest, by symulacja precyzyjnie odwzorowywała rzeczywistość. Oznacza to przede wszystkim konieczność uwzględnienia modeli matematycznych sensorów, generujących sztuczne pomiary wiernie naśladujące dane zwracane przez rzeczywiste czujniki. Jak wspomniano, radary samochodowe pełnią kluczową rolę we współczesnych systemach typu ADAS. Niestety, sensory te są silnie niedeterministyczne, głównie ze względu na losowość procesu propagacji fali elektromagnetycznej. Dlatego też opracowanie modelu matematycznego czujnika radarowego jest zadaniem nietrywialnym. Istotna jest tutaj nie tylko dokładność odwzorowania, ale także niska złożoność obliczeniowa modułu, by umożliwić wirtualny test układu typu ADAS w czasie rzeczywistym.

W literaturze opisano do tej pory wiele skutecznych rozwiązań. Niemniej jednak analizując dostępne prace można zauważyć, że wciąż nie opisano metody charakteryzującej się zarówno wysokim poziomem wiarygodności, jak i prostotą w opracowaniu i w kalibracji. W tej pracy omówiono innowacyjny model matematyczny czujnika radarowego oparty na niezwykle ciekawej koncepcji centrów rozpraszania, reprezentujących w przybliżony sposób rozproszenie fali elektromagnetycznej w przestrzeni. Model ten dostosowano do wymagań przemysłu motoryzacyjnego związanych z weryfikacją urządzeń klasy ADAS w symulacji. Po pierwsze, model sformalizowano pod kątem kluczowego w dziedzinie wirtualnej walidacji standardu ASAM OSI. Po drugie, na bazie pomiarów z rzeczywistych czujników radarowych zidentyfikowano i wprowadzono do modelu modyfikacje mające na celu zwiększenie rzetelności procesu

generacji sztucznych pomiarów w ważnych z perspektywy systemów typu ADAS scenariuszach jazdy. Po trzecie, przeprowadzono procedurę identyfikacji parametrów modelu. W końcu, z wykorzystaniem autorskiej metody weryfikacji, udowodniono zarówno wiarygodność zmodyfikowanego modelu, jak i jego zdolność do pracy w czasie rzeczywistym. Co za tym idzie, uzasadniono, iż model matematyczny czujnika radarowego bazujący na koncepcji centrów rozpraszania może być użyteczny w kontekście testów systemu klasy ADAS w czasie rzeczywistym w symulatorze jazdy, niezależnie od poziomu skomplikowania wirtualnego scenariusza.

## 2 Motywacja

W 1999 roku koncern samochodowy Mercedes-Benz zaprezentował przełomowy model W220, czyli pierwszy seryjnie produkowany pojazd, który wyposażono w czujnik radarowy. Radar (ang. Radio Detection and Ranging) zamontowano na potrzeby systemu o nazwie Distronic, realizującego funkcjonalność tzw. aktywnego tempomatu (ang. Adaptive Cruise Control, ACC). Opracowanie automatycznej regulacji prędkości zapoczątkowało gwałtowny rozwój zaawansowanych systemów wspomagania kierowcy (ang. Advance Driver Assistance Systems, ADAS). W szczególności zaczęto pracować nad zaawansowanym systemem hamowania awaryjnego (ang. Advanced Emergency Braking System, AEB), gdzie również kluczową rolę odgrywa czujnik radarowy. Układ typu AEB okazał się tak ważny dla zapewnienia bezpieczeństwa w ruchu drogowym, że Unia Europejska rozpoczęła pracę nad sporządzeniem norm homologacyjnych dla pojazdów silnikowych. I tak w 2009 roku wydano rozporządzenie nakładające obowiązek montażu tego typu urządzeń w pojazdach ciężarowych. W roku 2019 normę rozszerzono również o samochody osobowe. Dodatkowo do listy układów typu ADAS, które muszą być uwzględnione w każdym nowo wyprodukowanym pojeździe od 2022 roku, zaliczono także urządzenia oparte na czujnikach wizyjnych, takie jak: inteligentny asystent kontroli prędkości (ang. Intelligent Speed Assistance, ISA) czy system awaryjnego utrzymania pojazdu w pasie ruchu (ang. Emergency Lane-Keeping System, ELKS). Wynika z tego, że czujniki radarowe (oraz kamery) to obecnie nie tylko domena modeli luksusowych. Sensory te stały się nieodłącznym elementem każdego pojazdu silnikowego.

Regulacje nałożone przez Unię Europejską na przemysł motoryzacyjny są ewidentnym potwierdzeniem trendu we współczesnych układach typu ADAS. Mianowicie, tego typu urządzenia przyjmują coraz większą odpowiedzialność za bezpieczeństwo pasażerów pojazdu oraz wszystkich uczestników ruchu drogowego, przejmując kontrolę nad maszyną w krytycznych sytuacjach. Rosnący wpływ systemów należących do kategorii ADAS na trajektorię jazdy można uzasadnić faktem, iż znaczna część wypadków spowodowana jest przez nieuwagę kierowcy lub niedostosowaniem się do warunków panujących na jezdni.

Tak wysoki poziom ingerencji urządzeń klasy ADAS w ruch pojazdu skutkuje tym, że przed wdrożeniem do produkcji każdy tego typu system poddany zostaje rzetelnej weryfikacji. Procedura oceny jakości i niezawodności zaprojektowanego rozwiązania jest niezwykle czasochłonna i kosztowna. Wymaga ona przeprowadzenia szeregu jazd testowych, by sprawdzić zachowanie układu w potencjalnie niebezpiecznych sytuacjach. Dlatego też, chcąc uprościć walidację systemu, producenci samochodów decydują się na przeprowadzenie części eksperymentów w symulatorach jazdy. Dzięki takiej wirtualnej

walidacji proces oceny układu klasy ADAS jest zdecydowanie mniej czasochłonny. Dodatkowo można także sprawdzić działanie rozwiązania w skrajnie groźnych sytuacjach, które - ze względów bezpieczeństwa - byłoby niezwykle trudno odtworzyć w rzeczywistości.

Do rzetelnego przetestowania urządzenia na sztucznie wygenerowanych danych konieczne jest, by symulator wiernie odtwarzał rzeczywiste scenariusze jazdy. Oznacza to, że mechanizm renderujący środowiska wirtualnego musi szczegółowo powielać kontury wszystkich elementów sceny oraz odwzorowywać różne warunki atmosferyczne. Ponadto symulator musi uwzględniać dokładne modele fizyki ruchu obiektów. Jednak, co najważniejsze, do uruchomienia układu typu ADAS w wirtualnej rzeczywistości wymagany jest moduł odpowiedzialny za generację danych imitujących informacje zwracane przez rzeczywiste czujniki. Wydaje się, że jest to szczególnie skomplikowane w przypadku radaru, czyli kluczowego czujnika w kontekście systemów ACC i AEBS. Za szczególnie kłopotliwe należy uznać zamodelowanie procesu wiernie naśladowującego propagację sygnału elektromagnetycznego w przestrzeni. Trudność ta wynika przede wszystkim z poziomu skomplikowania procesu rozprzestrzeniania się impulsów radiowych w ośrodkach o gęstym rozmieszczeniu obiektów. W tego typu środowiskach pomiary radarowe są zakłócane głównie przez zjawisko wielokrotnego załamania fali, czego skutkiem jest pojawienie się fałszywych wykryć w zbiorze danych radarowych. Dodatkowo należy uwzględnić także tzw. efekt mikro Dopplera, czyli błędny odczyt prędkości względnej spowodowany przez obracające się koła pojazdu. Jednak warunkiem, który musi spełnić model matematyczny czujnika radarowego, jest nie tylko wysoki poziom realizmu sztucznie generowanych pomiarów. Kluczowym kryterium jest także niska złożoność obliczeniowa modułu umożliwiająca przetestowanie urządzenia typu ADAS z wykorzystaniem techniki tzw. symulacji w pętli sprzętowej (ang. hardware in the loop, HIL), gdzie system weryfikuje się w czasie rzeczywistym.

Modele czujników radarowych dzielą się na dwie kategorie: są to modele bazujące na danych oraz modele geometryczne. Do pierwszej kategorii przypisuje się modele wytwarzające wirtualne dane w sposób niejawni, przez odpowiednio zdefiniowany model statystyczny lub sztuczną sieć neuronową. W ostatnich latach powstało wiele tego typu przełomowych algorytmów w takich dziedzinach, jak np.: klasyfikacja obrazu czy wykrywanie obiektów. Osiągnięte rezultaty pokazują, że przy użyciu tej metodologii, określanej często mianem techniki tzw. czarnej skrzynki, można odwzorować złożone, nieliniowe operacje. Niestety, biorąc pod uwagę stopień skomplikowania samochodowych systemów radarowych, do opracowania rzetelnego i wszechstronnego algorytmu bazującego na metodzie czarnej skrzynki wymagana jest grupa ucząca zawierająca ogromną liczbę należycie zróżnicowanych, oznaczonych informacji. Innymi słowy, zaprojektowanie modelu odpornego na problem tzw. nadmiernego dopasowania (ang. overfitting) to niesłychanie trudny i kosztowny proces.

Do drugiej kategorii należy zaliczyć wszystkie rozwiązania, w których syntetyczne pomiary generowane są na podstawie informacji udostępnionych przez symulator jazdy poprzez z góry ustalone funkcje matematyczne. Takie podejście jest praktycznie niezależne od danych rzeczywistych, gdyż do identyfikacji parametrów modelu jest konieczna tylko niewielka liczba pomiarów. Najdokładniejszy będzie tzw. model fizyczny, gdzie uwzględnia się każdy aspekt funkcjonowania rzeczywistego sensora, w tym szczególnie odwzorowanie procesu propagacji fali elektromagnetycznej. Wadą tej metody jest natomiast spora złożoność obliczeniowa, wynikająca z konieczności wykonania procedury śledzenia

promieni (ang. ray tracing), dzięki któremu model ma dostęp do szczegółowych danych o konturach obiektów wygenerowanych przez środowisko wirtualnej jazdy.

Geometryczny model czujnika radarowego może być jednak zrealizowany przy użyciu metody wymagającej zdecydowanie mniejszej ilości zasobów obliczeniowych, gdzie nie jest konieczna bezpośrednia symulacja propagacji sygnału radiowego w przestrzeni. Metodologia ta opiera się na koncepcji tzw. centrów rozpraszania znanej ze studiów nad skuteczną powierzchnią odbicia radaru (ang. radar cross section, RCS). Idea ta mówi, że odbicie (rozproszenie) fali elektromagnetycznej od dużego obiektu może być przybliżone za pomocą pewnego zbioru punktów zlokalizowanych na tym obiekcie. Innymi słowy, do wygenerowania sztucznych pomiarów radarowych wykorzystuje się jedynie informacje o obiektach zdefiniowanych w danym scenariuszu wirtualnej jazdy; istotne są tutaj następujące parametry: pozycja, wymiary, kinematyka czy też typ konkretnego celu. Oczywiście takie podejście jest sporym uproszczeniem w odniesieniu do rzetelnie opracowanego modelu fizycznego. Okazuje się jednak, że uzupełniając symulację bazującą na centrach rozpraszania o dodatkowy generator zakłóceń podejście to może być wystarczające do uzyskania sztucznego zbioru wykryć radarowych o podobnych właściwościach stochastycznych w stosunku do rzeczywistych pomiarów.

### 3 Teza pracy

Zdefiniujmy wpieryw pojęcia, przy użyciu których można scharakteryzować model matematyczny czujnika:

- (i) **Wiarygodność** - model matematyczny uznaje się za wiarygodny, kiedy wartości wyliczone dla przyjętych wskaźników jakości mieszczą się w ustalonym przedziale błędu, niezależnie od poziomu skomplikowania i charakterystyki scenariusza wirtualnej jazdy, w którym uruchomiono dany model.
- (ii) **Wydajność** - model matematyczny uznaje się za wydajny, jeśli złożoność obliczeniowa modelu pozwala na uruchomienie symulacji (układu klasy ADAS) w czasie rzeczywistym dla scenariuszy o wysokim stopniu natężenia ruchu.
- (iii) **Użyteczność** - model matematyczny jest użyteczny w kontekście wirtualnej walidacji systemów typu ADAS wtedy, gdy jest on wiarygodny i wydajny.

W literaturze opisano do tej pory wiele skutecznych rozwiązań, opartych na wszystkich omówionych w poprzednim podrozdziale metodologiach. Analizując dostępne prace, nietrudno wskazać w każdej z omówionych technik co najmniej jeden istotny problem:

- (i) **Problem czarnej skrzynki** - wysoka zależność od pomiarów z rzeczywistego czujnika: zaprojektowanie oraz wyuczenie sztucznej sieci neuronowej generującej syntetyczny zbiór wykryć radarowych cechujący się wiarygodnością wymaga zgromadzenia niezwykle obszernego zbioru uczącego, co jest niesłychanie czasochłonnym i kosztownym procesem.
- (ii) **Problem modeli fizycznych** - duża złożoność obliczeniowa: wiarygodne odwzorowanie procesu propagacji fali elektromagnetycznej w przestrzeni w symulatorze jazdy wymaga dostępu do szczegółowych informacji na temat konturów obiektów zdefiniowanych dla danego momentu scenariusza, co pociąga za sobą konieczność wykonania kosztownej pod kątem zużycia zasobów komputera operacji śledzenia promieni.

- (iii) Problem modeli bazujących na technice centrów rozpraszania - trudność w uzyskaniu wysokiego stopnia wiarygodności: pominięcie procesu propagacji sygnału elektromagnetycznego w przestrzeni powoduje, że model matematyczny nie zawiera odpowiedniej ilości zakłóceń charakterystycznych dla rzeczywistego czujnika radarowego.

Teza dysertacji jest zatem następująca:

*Możliwa jest adaptacja sztucznego zbioru danych wygenerowanego przy użyciu modelu matematycznego czujnika radarowego bazującego na koncepcji centrów rozpraszania pod kątem użyteczności w kontekście testów systemu klasy ADAS w czasie rzeczywistym w symulatorze jazdy.*

## 4 Najważniejsze wyniki pracy

W tej części opisane będą pokrótce najważniejsze osiągnięcia pracy.

### 4.1 Formalizacja modelu matematycznego pod kątem standardu ASAM OSI

Zintegrowanie modelu matematycznego ze standardem ASAM OSI, kluczowym w kontekście wirtualnej walidacji systemów typu ADAS, nie było zadaniem trywialnym. Należało przeprowadzić następujące czynności:


- (i) Zdefiniowanie w jednoznaczny sposób wejścia do modelu oraz wyjścia z modelu.
- (ii) Określenie powiązania pomiędzy typami obiektów wspieranymi przez oryginalny model radaru a typami obiektów dostępnych w strukturze *OSI::VehicleClassification*
- (iii) Wprowadzenie szeregu wzorów umożliwiających formalny i kompaktowy zapis operacji wykonywanych w ramach modelu matematycznego, co przyczyniło się do określenia jasnej i czytelnej definicji wskaźnika jakości.

Przykładowy przepływ informacji w modelu sensora - od uzyskania wiadomości *OSI::SensorView* o stemplu czasowym  $t$ , uwzględniającej obiekty klasy *OSI::MovingObject* oraz elementy typu *OSI::StationaryObject*, poprzez wywołanie wszystkich omówionych w dysertacji procedur, aż po wygenerowanie poprawnej struktury *OSI::SensorData* ze zbiorem sztucznych wykryć radarowych  $\hat{P}_d^t$  zaprezentowano na rysunku 1, gdzie  $|\hat{P}_d^t|$  to liczba elementów zestawu  $\hat{P}_d^t$ .

### 4.2 Dodanie nowatorskich usprawnień do oryginalnego modelu matematycznego


Na podstawie prawdziwych danych autor zidentyfikował, iż rzeczywisty czujnik radarowy typu FMCW (zaprojektowany dla przemysłu motoryzacyjnego) charakteryzuje się trzema następującymi właściwościami: bardzo mała gęstość pomiarowa, obecność fałszywych wykryć niepowiązanych z żadnym rzeczywistym obiektem oraz generacja danych zarówno dla obiektów statycznych, jak i dla celów ruchomych. Oryginalny model matematyczny usprawniono zatem o następujące funkcjonalności: rozszerzono model o wsparcie dla obiektów statycznych, dodano moduł odpowiedzialny za generację fałszywych wykryć oraz wprowadzono specjalny filtr rozdzielczości, mający na celu zredukowanie zagęszczenia zbioru sztucznych wykryć.

Poniżej zaprezentowano wyniki: rysunek 2 pokazuje rzeczywiste wykrycia radarowe, rysunek 3 prezentuje sztuczne dane uzyskane przy użyciu oryginalnego modelu matematycznego, natomiast na




**Rysunek 1.** Przykładowy przepływ informacji w zmodyfikowanym modelu symulacyjnym czujnika radarowego kompatybilnym ze standardem ASAM OSI, wspierającym generację zbioru sztucznych wykryć zarówno dla obiektów klasy *OSI::MovingObject*, jak i dla obiektów typu *OSI::StationaryObject*


rysunku 4 przedstawiono sztuczne pomiary uzyskane dla zmodyfikowanego modelu. Widać wyraźnie, że rysunek 4, w przeciwieństwie do rysunku 3, jest zbliżony do danych rzeczywistych widocznych na rysunku 2.



**Rysunek 2.** Zbiór rzeczywistych pomiarów radarowych



**Rysunek 3.** Zbiór sztucznych wykryć radarowych wygenerowanych przy użyciu oryginalnego modelu sensora



**Rysunek 4.** Zbiory sztucznych wykryć radarowych wygenerowanych przy użyciu zmodyfikowanego modelu sensora (po wprowadzeniu opisanych wyżej modyfikacji)



### 4.3 Opracowanie i wykonanie procedury identyfikacji parametrów modelu z oryginalnie dobranym wskaźnikiem jakości

Przy projektowaniu wskaźnika jakości autor inspirował się metodologią przyjętą w artykule "Efficient characterization method for big automotive datasets used for perception system development and verification" opublikowanym w 2022 roku przez Pawła Kowalczyka, Pawła Skrucha i Marcina Szelesta. Innymi słowy, w dysertacji opracowano wskaźnik jakości bazujący na metryce Wassersteina porównującej dwuwymiarowe histogramy.

Wpierw autor wprowadził formułę (1) na sumaryczny zbiór wykryć  $\mathbb{P}^t \subset \mathbb{R}^2$  wyrażony w kartezyjskim układzie współrzędnych. Miał on zawierać wszystkie punkty na płaszczyźnie  $\mathbb{R}^2$ , dla których w momencie czasu  $t$  istniało co najmniej jedno wykrycie zwrócone przez czujniki radarowe wykorzystane w omawianej procedurze -  $P_d^{FL,t}$ ,  $P_d^{FR,t}$ ,  $P_d^{RL,t}$  oraz  $P_d^{RR,t}$ :

$$\mathbb{P}^t = \left\{ \{x, y\} \in \mathbb{R}^2 : x = R \cos \theta, y = R \sin \theta : \{R, \theta\} \in P_d^{FL,t} \cup P_d^{FR,t} \cup P_d^{RL,t} \cup P_d^{RR,t} \right\}. \quad (1)$$

Następnie zdefiniowano dyskretną siatkę  $G_h$  określoną na płaszczyźnie  $\mathbb{R}^2$ :

$$G_h(i) = \left\{ \{x, y\} \in \mathbb{R}^2 : \left\lfloor \frac{x}{h_x} \right\rfloor = i_1, \left\lfloor \frac{y}{h_y} \right\rfloor = i_2 \right\}, \quad (2)$$

gdzie  $h = \{h_x, h_y\} \in \mathbb{R}^2$ ,  $h_x > 0$ ,  $h_y > 0$ ,  $i = \{i_1, i_2\} \in \mathbb{Z}^2$ ,  $\left\lfloor \frac{x}{h_x} \right\rfloor$  to największa liczba całkowita nie większa od ilorazu  $x/h_x$ ,  $\left\lfloor \frac{y}{h_y} \right\rfloor$  to największa liczba całkowita nie większa od ilorazu  $y/h_y$ , natomiast  $\mathbb{Z}$  reprezentuje zbiór liczb całkowitych. Następnie wykonano rzut zbioru  $\mathbb{P}^t$  na siatkę zdefiniowaną we wzorze (2). Przekształcony zestaw  $\mathbb{P}_h^t$  uzyskuje się według takiej oto formuły:

$$\mathbb{P}_h^t = \left\{ i \in \mathbb{Z}^2 : \exists \{x, y\} \in \mathbb{P}^t : \{x, y\} \in G_h(i) \right\}. \quad (3)$$

Zauważmy, iż ilość elementów zbioru  $\mathbb{P}_h^t$  jest zależna od wartości parametru  $h$ , który należy dobrać pod kątem konkretnej aplikacji. Niech  $H^t : \mathbb{P}_h^t \rightarrow \mathbb{N}$  będzie tzw. histogramem zajętości określonym dla dyskretnego momentu czasu  $t$ :

$$H^t(i) = \sum_{P_d^t \in \mathfrak{P}^t} \left| \left\{ \{x, y\} \in \mathbb{R}^2 : x = R \cos \theta, y = R \sin \theta : \{R, \theta\} \in P_d^t \wedge \{x, y\} \in G_h(i) \right\} \right|, \quad (4)$$

gdzie  $\mathfrak{P}^t = \{P_d^{FL,t}, P_d^{FR,t}, P_d^{RL,t}, P_d^{RR,t}\}$ , natomiast  $|\cdot|$  oznacza ilość elementów zbioru. Dla przestrzeni  $\mathbb{P}_h^t$  sformułowanej w równaniu (3) zdefiniowano dyskretny rozkład prawdopodobieństwa  $\mu : \mathbb{P}_h^t \rightarrow [0, 1]$  w taki oto sposób:

$$\mu(i) = \frac{H^t(i)}{\sum_{j \in \mathbb{P}_h^t} H^t(j)}, \quad i \in \mathbb{P}_h^t. \quad (5)$$

Wykorzystując wprowadzone wyżej definicje zmodyfikowano wzór na odległość Wassersteina stopnia  $p$  tak, by był odpowiedni dla rozważanego dyskretnego problemu. Mianowicie, zadanie obliczenia metryki Wassersteina w przypadku dwóch rozkładów prawdopodobieństwa  $\mu$  i  $\nu$  określonych

na podstawie równania (5) potraktowano jako zagadnienie z kategorii optymalnego transportu, które znajduje rozwiązanie poprzez sprowadzenie go do postaci problemu programowania liniowego. Dla każdego zbioru  $\mathbb{P}_h^t$  można zdefiniować funkcję wzajemnie jednoznaczna  $\eta : \mathbb{M} \rightarrow \mathbb{P}_h^t$ , gdzie  $\mathbb{M} = \{1, \dots, |\mathbb{P}_h^t|\}$ . Oznaczmy  $|\mathbb{P}_h^t|$  jako  $\mathcal{M}$ . Żeby obliczyć odległość Wassersteina  $W(\mu, \nu)$ , należy znaleźć funkcję  $f^* : \mathbb{M} \times \mathbb{M} \rightarrow [0, 1]$ , która minimalizuje sumę:

$$\sum_{k=1}^{\mathcal{M}} \sum_{j=1}^{\mathcal{M}} f(k, j) d(k, j), \quad (6)$$

gdzie  $d(k, j)$  to odległość Euklidesowa pomiędzy wektorami  $\eta(k)$  oraz  $\eta(j)$ . Ograniczenia dla funkcji  $f^*$  są następujące:

$$\begin{aligned} \forall k, j \in \mathbb{M} : 0 \leq f(k, j) \leq 1, \\ \forall k \in \mathbb{M} : \sum_{j=1}^{\mathcal{M}} f(k, j) &= \mu(\eta(k)), \\ \forall j \in \mathbb{M} : \sum_{k=1}^{\mathcal{M}} f(k, j) &= \nu(\eta(j)), \\ \sum_{k=1}^{\mathcal{M}} \sum_{j=1}^{\mathcal{M}} f(k, j) &= 1. \end{aligned} \quad (7a-d)$$

Ostatecznie, odległość Wassersteina  $W(\mu, \nu)$  stopnia  $p$  oblicza się na podstawie równania:

$$W(\mu, \nu) = \left( \sum_{k=1}^{\mathcal{M}} \sum_{j=1}^{\mathcal{M}} f^*(k, j) d(k, j) \right)^{\frac{1}{p}}. \quad (8)$$


Przyjęto, iż ostateczna wartość wskaźnika jakości (dla danych wartości nastaw) będzie średnią arytmetyczną obliczoną na podstawie 100 kolejnych okresów odczytu. Innymi słowy, wartość wskaźnika jakości  $\mathbb{W}$  wykorzystywaną przez omawianą procedurę optymalizacji oblicza się według następującej formuły:

$$\mathbb{W} = \frac{1}{100} \sum_{i=1}^{100} W^i(\mu, \nu), \quad (9)$$

gdzie  $W^i(\mu, \nu)$  jest odległością Wassersteina drugiego stopnia uzyskaną dla pakietu danych o indeksie  $i$  na podstawie równania (8). Jako algorytm optymalizacji wybrano metodę Powella, dzięki której można skutecznie wyznaczyć minimum nieliniowej funkcji wielu zmiennych, bez konieczności obliczania pochodnych. Technika ta idealnie sprawdzi się zatem w tym przypadku, gdyż wskaźnik jakości wylicza się dla pewnego procesu stochastycznego, kontrolowanego przez parametry wymienione w tabeli.

Rezultaty identyfikacji parametrów modelu zaprezentowano na rysunku 5. Warto zaznaczyć, że rysunek 5 wygenerowano w formie tak zwanej mapy ciepła. Mianowicie, we wszystkich pokazanych niżej przypadkach pomiary zrzutowano na dwuwymiarową siatkę o komórkach długości 0.5 [m] i szerokości 0.5 [m]. Następnie każdemu elementowi siatki przypisany został kolor, na podstawie liczby

wykryć, jaką zakwalifikowano do tego elementu; przy czym zależność barwy od liczby pomiarów ukazano na pasku kolorów widocznym po prawej stronie rysunku. Oczywiście należy tutaj wspomnieć, iż obecność punktu na omawianym rysunku oznacza, że w danej komórce znalazło się co najmniej jedno wykrycie.

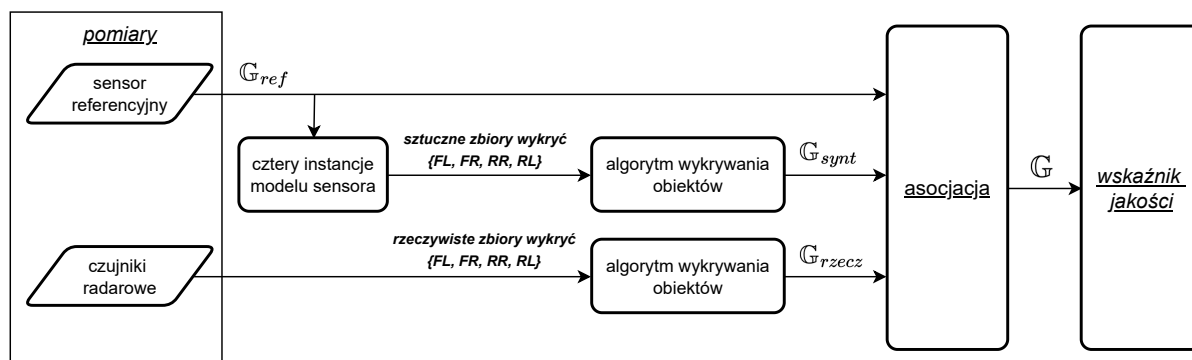


**Rysunek 5.** Mapy ciepła wygenerowane dla czterech typów danych zebranych ze 100 kolejnych okresów odczytu - rzeczywisty zbiór wykryć (lewy górny róg), sztuczny zbiór wykryć uzyskany dla nastaw zwróconych przez algorytm Powella (prawy górny róg) oraz syntetyczny zestaw pomiarów uzyskany dla nastaw odpowiadających kolejno dolnemu (zbyt duża rozdzielczość) i górnemu (zbyt niska rozdzielczość) zakresowi ograniczeń.

Widać, że sztuczne dane widoczne w prawym górnym rogu najbardziej zbliżone są do rzeczywistych pomiarów, co potwierdza skuteczność procedury identyfikacji parametrów modelu.

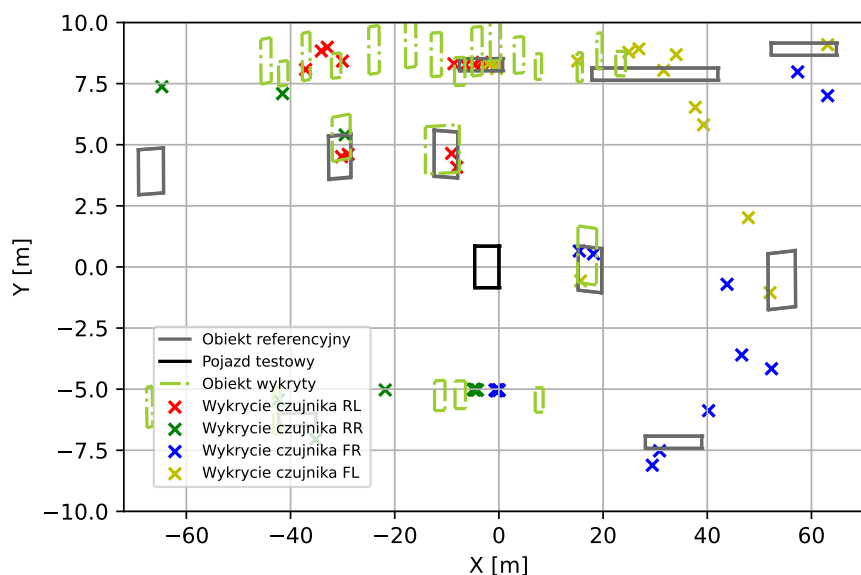
## 5 Zrealizowanie autorskiej metody oceny wiarygodności modelu

Dzięki przeprowadzeniu wspomnianej metody oceny wiarygodności i wydajności potwierdzono użyteczność modelu sensora w kontekście wirtualnej walidacji systemów typu ADAS. Graficzną reprezentację tejże procedury pokazano na schemacie blokowym widocznym na rysunku 6, gdzie  $\mathbb{G}_{ref}$ ,  $\mathbb{G}_{rzecz}$  i  $\mathbb{G}_{synt}$ , to kolejno: referencyjna, rzeczywista oraz syntetyczna lista obiektów. Warto zaznaczyć, że w tym przypadku wskaźnik jakości jest obliczany w podobny sposób, jak w poprzednim rozdziale (dyskretna metryka Wassersteina), lecz tutaj pomiarem jest współczynnik podobieństwa Jaccarda (ang. Intersection over Union, IoU).

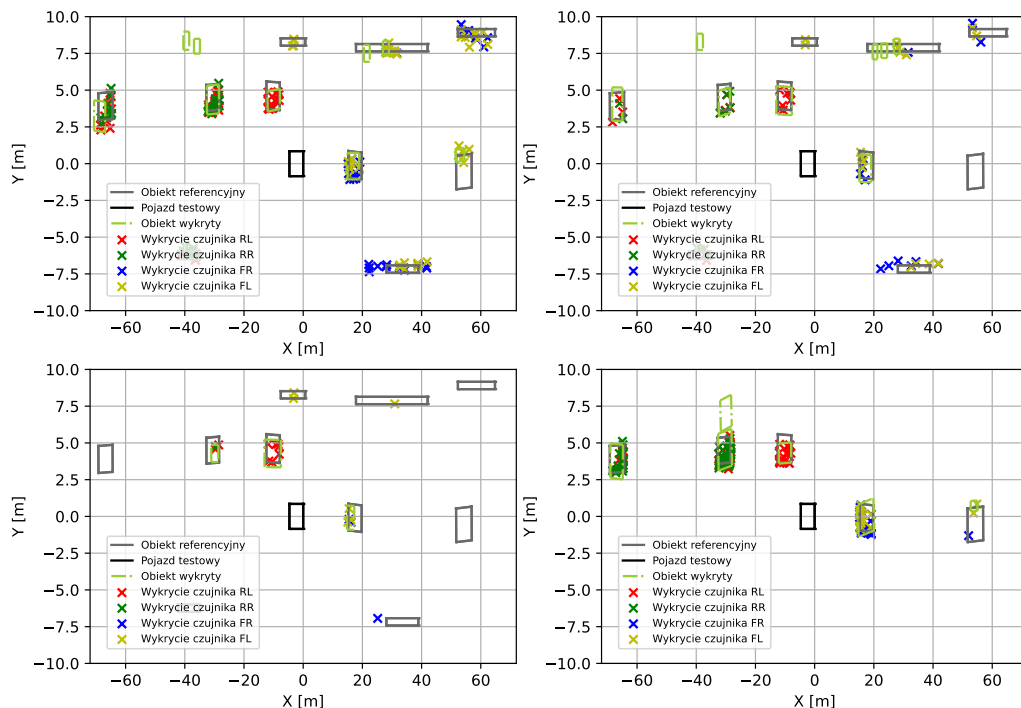


**Rysunek 6.** Schemat blokowy ukazyjący uproszczony przepływ danych w procedurze weryfikacji wiarygodności modelu sensora

Rezultaty procedury weryfikacji pokazano na rysunkach 7 oraz 8. Widać, że potwierdzono skuteczność nastaw optymalnych.



**Rysunek 7.** Lista brył brzegowych oszacowana przez algorytm wykrywania obiektów na podstawie rzeczywistych pomiarów radarowych



**Rysunek 8.** Lista brył brzegowych oszacowana przez algorytm wykrywania obiektów na podstawie sztucznych pomiarów wygenerowanych przez model sensora skonfigurowany przy użyciu: nastaw o zbyt dużej rozdzielczości (lewy górny róg), nastaw optymalnych (prawy górny róg), nastaw o zbyt niskiej rozdzielczości (lewy dolny róg), nastaw właściwych dla oryginalnego modelu sensora (prawy dolny róg).

## 6 Podsumowanie

Celem pracy była adaptacja innowacyjnego modelu matematycznego czujnika radarowego, opisanego w artykule "Uncertainty propagation for vehicle detections in experimentally validated radar model for automotive application" opublikowanym w 2019 roku przez trzyosobowy zespół prowadzony przez Adama Martowicza, pod kątem wymagań przemysłu motoryzacyjnego dotyczących testów systemów typu ADAS w środowiskach wirtualnej jazdy. Innymi słowy, zadanie polegało na zidentyfikowaniu oraz wprowadzeniu do oryginalnego modelu szeregu modyfikacji, przy użyciu nieznacznej ilości danych rzeczywistych, tak, by model charakteryzował się wysokim poziomem wiarygodności i wydajności.

Zauważmy, że stwierdzenie wiarygodności i wydajności modelu jest wystarczające do udowodnienia postawionej na początku tezy, iż model matematyczny czujnika radarowego bazujący na koncepcji centrów rozpraszania może być użyteczny w kontekście testów systemu urządzeń typu ADAS w czasie rzeczywistym w symulatorze jazdy, niezależnie od stopnia skomplikowania wirtualnego scenariusza. By udowodnić postawioną tezę należy więc ocenić, czy sztuczne dane wygenerowane przy użyciu modelu sensora wiernie odwzorowują pomiary z rzeczywistego systemu radarowego.

Żeby to osiągnąć, przeprowadzono dwie kluczowe operacje. Wpierw wykonano procedurę identyfikacji parametrów modelu z oryginalnie dobranym wskaźnikiem jakości bazującym na metryce Wassersteina porównującym w bezpośredni sposób rzeczywisty i sztuczny zbiór wykryć; umożliwiło to dobranie odpowiednich ustawień modelu, czyli takich, dla których funkcja kosztu osiąga najniższą wartość. W końcu przeprowadzono ocenę wiarygodności sztucznie generowanych pomiarów z użyciem autorskiej metody walidacji modelu matematycznego czujnika radarowego, polegającej na wykorzystaniu listy brył brzegowych utworzonej przez algorytm wykrywania obiektów. Innymi słowy, wygenerowano dwa zestawy brył brzegowych, a więc dla danych rzeczywistych oraz dla danych syntetycznych, które następnie porównano ze sobą, stosując kolejny raz metrykę Wassersteina, choć w tym wypadku z inną funkcją odległości.

Rezultaty osiągnięte w procesie weryfikacji modelu sensora jednoznacznie pokazują, że wirtualny radar zbudowany na bazie koncepcji centrów rozpraszania po wprowadzeniu opisanych wyżej modyfikacji w sposób wiarygodny odwzorowuje dane zwracane przez rzeczywisty system radarowy. Co najważniejsze, rozmieszczenie poszczególnych wykryć jest zbliżone do pomiarów generowanych przez wykorzystany radar samochodowy. Ponadto algorytm wykrywania obiektów wytwarza zbieżne listy brył brzegowych zarówno dla informacji rzeczywistych, jak i syntetycznych. W końcu zweryfikowano także zdolność modelu matematycznego do pracy w czasie rzeczywistym. Potwierdza to zatem tezę, że zmodyfikowany model sensora jest użyteczny w procesie weryfikacji urządzeń klasy ADAS w środowiskach wirtualnej jazdy.

Podsumowując, za główny wkład pracy w odniesieniu do celu i tezy rozprawy należy uznać:

- (i) Formalizację modelu pod kątem standardu ASAM OSI, w szczególności: zdefiniowanie w jednoznaczny sposób wejścia do modelu oraz wyjścia z modelu zgodnego ze standardem ASAM OSI, określenie powiązania pomiędzy typami obiektów wspieranymi przez oryginalny model radaru a typami obiektów dostępnych w strukturze *OSI::VehicleClassification*, wprowadzenie szeregu wzorów umożliwiających formalny i kompaktowy zapis operacji wykonywanych w ramach modelu matematycznego, co przyczyniło się do określenia jasnej i czytelnej definicji wskaźnika jakości.
- (ii) Zidentyfikowanie opisanych wyżej obszarów, w których oryginalny model matematyczny może być udoskonalony, na podstawie pomiarów z rzeczywistego czujnika radarowego.
- (iii) Dodanie nowatorskich usprawnień do wspomnianego modelu matematycznego, takich jak: rozszerzenie modelu o wsparcie dla obiektów statycznych, dodanie modułu odpowiedzialnego za generację fałszywych wykryć oraz wprowadzenie specjalnego filtra rozdzielczości, mającego na celu zredukowanie zagęszczenia zbioru sztucznych wykryć.
- (iv) Opracowanie i wykonanie procedury identyfikacji parametrów modelu z oryginalnie dobranym wskaźnikiem jakości.
- (v) Zrealizowanie autorskiej metody oceny wiarygodności i wydajności modelu, dzięki czemu potwierdzono użyteczność modelu sensora w kontekście wirtualnej walidacji systemów typu ADAS.

Warto na koniec wspomnieć, że rezultaty pracy zostały wdrożone do praktyki przemysłowej do weryfikacji elektronicznych systemów sterownia jazdy automatycznej na poziomie L2-L3 przeznaczonych do produkcji seryjnej dla kluczowym producentów samochodów.

## 7 Wykaz publikacji i osiągnięć autora

Wykaz publikacji autora:

- (i) **Michał Jasiński**, "A Generic Validation Scheme for real-time capable Automotive Radar Sensor Models integrated into an Autonomous Driving Simulator," 2019 24th International Conference on Methods and Models in Automation and Robotics (MMAR), 2019, pp. 612-617, doi: 10.1109/MMAR.2019.8864669.
- (ii) Kamil Lelowicz, **Michał Jasiński** i Marcin Piątek. "Generic Sensor Model for Object Detection Algorithms Validation. In: Bartoszewicz, A., Kabziński, J., Kacprzyk, J. (eds) Advanced, Contemporary Control. Advances in Intelligent Systems and Computing, vol 1196. Springer, Cham. [https://doi.org/10.1007/978-3-030-50936-1\\_104](https://doi.org/10.1007/978-3-030-50936-1_104).
- (iii) **Michał Jasiński**. "Method for Road Occlusions Handling in Generic Sensor Models," 2021 25th International Conference on Methods and Models in Automation and Robotics (MMAR), 2021, pp. 179-184, doi: 10.1109/MMAR49549.2021.9528443.
- (iv) **Michał Jasiński**, Paweł Skruch i Mateusz Komorkiewicz. "Validation Framework for Generic Radar Sensor Models," in IEEE Access, vol. 10, pp. 18257-18267, 2022, doi: 10.1109/ACCESS.2022.3150284.
- (v) Kamil Lelowicz, **Michał Jasiński** i Adam Krzysztof Piąt. "Discussion of Novel Filters and Models for Color Space Conversion," in IEEE Sensors Journal, vol. 22, no. 14, pp. 14165-14176, 15 July 2022, doi: 10.1109/JSEN.2022.3169805.

Wykaz wniosków patentowych zgłoszonych w trakcie trwania doktoratu:

- (i) **Michał Jasiński** i Marcin Piątek "Method for simulating a digital imaging device". US202002942279A1, Aplikacja patentowa. 2020.