



AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE

DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

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

AUTOREFERAT ROZPRAWY DOKTORSKIEJ

*Detekcja wolnej przestrzeni wokół samochodu w oparciu o siatkę
zajętości*

Autor: *Marek Szlachetka*

Pierwszy promotor: *dr hab. inż. Jarosław Wąs, prof.AGH*

Drugi promotor: *dr hab. inż. Dariusz Borkowski*

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

Kraków, 2023

1 Streszczenie

Jednym z najważniejszych zagadnień w rozwoju Zaawansowanych Systemów Wspomagania Kierowcy jest percepcja otoczenia pojazdu. Systemy te składają się z kilku warstw zaczynając od warstwy czujników, przez warstwę percepcji, aż po warstwę planowania bezkolizyjnych manewrów.

Systemy percepcji służą do opisu otaczającego pojazd środowiska, zarówno dynamicznego, jak i stacjonarnego. Środowisko stacjonarne obejmuje wszystkie obiekty nieruchome, takie jak zaparkowane samochody (których system nie wykrył wcześniej jako poruszające się), budynki, bariery ochronne, krawężniki, znaki drogowe, itp. W literaturze można znaleźć wiele modeli matematycznych reprezentacji środowiska stacjonarnego, począwszy od prymitywnych kształtów, takich jak prostokąty czy koła, a kończąc na bardziej złożonych, takich jak siatki zajętości czy krzywe parametryczne.

W niniejszej pracy został zaproponowany algorytm wyznaczania i śledzenia granicy wolnej przestrzeni. Jako model matematyczny wykorzystano parametryczną krzywą sklejaną typu B-spline, a dane wejściowe stanowiła siatka zajętości. Wprowadzono kilka oryginalnych usprawnień najlepszego znanego w czasie pisania pracy algorytmu śledzenia granic wolnej przestrzeni. Uprawnienia te obejmują takie zagadnienia jak filtracja punktów pomiarowych, asocjacja punktów pomiarowych ze splajnem oraz dynamiczna modyfikacja punktów kontrolnych krzywej B-spline. Ostatnie usprawnienie wykorzystuje zaproponowane przez autora oryginalne wskaźniki lokalnej złożoności kształtu krzywej B-spline.

Algorytm proponowany w pracy został porównany z algorytmem referencyjnym na podstawie szerokiego zestawu sztucznych scenariuszy drogowych oraz jednego scenariusza rzeczywistego. Zdefiniowano metryki stosowane w porównaniu obu algorytmów, a następnie przeprowadzono dogłębną analizę wyników porównania. Uzyskane wyniki jednoznacznie wskazują, że zaproponowany algorytm oferuje lepszą jakość aproksymacji granic wolnej przestrzeni przy jednoczesnym skróceniu czasu wykonania algorytmu, co stanowi przewagę względem algorytmu referencyjnego.

2 Motywacja

Jednym z najistotniejszych problemów do rozwiązania podczas pracy na Zaawansowanymi Systemami Wspomagania Kierowcy (ADAS) jest precyzyjne odwzorowanie przestrzeni wolnej od przeszkód w której samochód może się bezpiecznie poruszać. Takimi przeszkodami, należącymi do środowiska stacjonarnego, są m.in. zaparkowane samochody, budynki, barierki, krawężniki, znaki, itp.

W branży automotive i jej podobnych takich jak robotyka, środowisko otaczające samochód można opisać za pomocą różnych modeli matematycznych. W literaturze istnieje kilka modeli używanych do opisu stacjonarnego środowiska, począwszy od prymitywnych struktur (prostokąt, okrąg itp.), a skończywszy na siatce zajętości lub krzywych parametrycznych. Wszystkie modele różnią się od siebie m.in. elastycznością (zdolność do odzwierciedlania złożonych kształtów), zajmowaną pamięcią czy zastosowaniem (scenariusz drogowy, dla którego są odpowiednie). Co więcej, różne modele mają różne zapotrzebowanie na pamięć i moc obliczeniową.

Jednym ze sposobów opisania granicy wolnej przestrzeni jest użycie krzywej parametrycznej. Przykładem tego jest podejście o nazwie *Parametric Free Space* (PFS), które wykorzystuje krzywą sklejaną typu B-Spline jako model matematyczny ze stałą liczbą punktów kontrolnych. Takie podejście ma jednak pewne wady. PFS nie może skutecznie dostosowywać położenia i liczby punktów kontrolnych do zmieniających się kształtów, gdy pojazd jest w ruchu. Użycie zbyt małej liczby punktów kontrolnych prowadzi do niskiej jakości aproksymacji, podczas gdy użycie zbyt wielu punktów kontrolnych znacznie wydłuża czas obliczeń. Pomimo użycia dużej liczby punktów kontrolnych, nie ma gwarancji osiągnięcia akceptowalnej jakości aproksymacji. Ponadto PFS zakłada, że punkty pomiarowe są równomiernie rozmieszczone, co w efekcie prowadzi do równomiernego rozmieszczenia punktów kontrolnych. Zmniejsza to elastyczność koncentrowania punktów kontrolnych na obszarach o większej złożoności

kształtu, kosztem skupiania ich na obszarach o niskiej złożoności kształtu. Innym aspektem dotyczącym punktów pomiarowych jest wykorzystanie wszystkich pomiarów bez filtrowania tych, które są zbędne tj. nie wnoszących dodatkowej informacji.

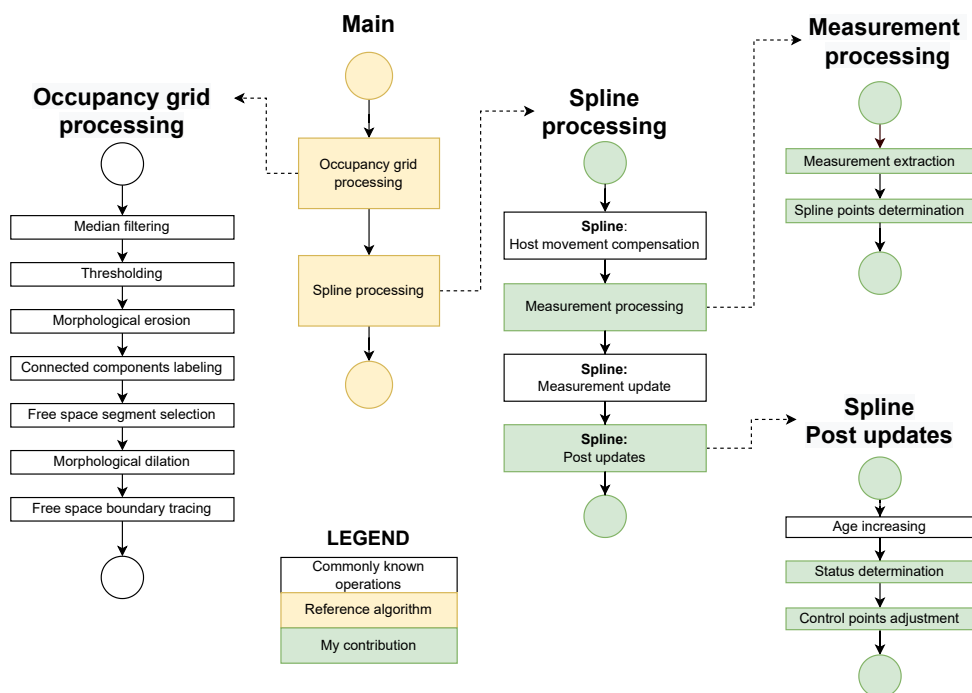
Estymacja i śledzenie granic wolnej przestrzeni ma zastosowanie w samochodowych systemach wbudowanych, a systemy te mają ograniczenia takie jak moc obliczeniowa, pamięć i maksymalny czas wykonania algorytmu. Dlatego algorytmy opracowywane dla systemów wbudowanych muszą być zbalansowane pomiędzy szybkością przy minimalnym zużyciu pamięci, a osiągnięciem wysokiej jakości aproksymacji.

3 Teza pracy

Filtracja punktów pomiarowych w połączeniu z dynamicznym dostosowaniem punktów kontrolnych definiujących krzywą sklejaną aproksymującą granice wolnej przestrzeni wokół pojazdu w algorytmie śledzenia granic wolnej przestrzeni wokół pojazdu pozwala na skrócenie czasu obliczeń i zmniejszenie ilości zajmowanej pamięci przy jednoczesnej poprawie jakości aproksymacji w stosunku do algorytmu wykorzystującego wszystkie dostępne punkty pomiarowe i stałą liczbę równomiernie rozmieszczonych punktów kontrolnych krzywej sklejaney.

4 Najważniejsze wyniki pracy

Głównym osiągnięciem pracy dyplomowej jest opracowanie algorytmu śledzenia granic wolnej przestrzeni wokół pojazdu za pomocą krzywej sklejaney 2D z dynamicznym doбором punktów kontrolnych (Rysunek 1) zawierającego liczne ulepszenia (wymienione poniżej) w odniesieniu do algorytmu referencyjnego.



Rysunek 1. Schemat proponowanego algorytmu z wyróżnieniem wkładu autora (oryginalne pomysły oznaczone kolorem zielonym).

4.1 Lokalna analiza kształtu krzywej

Pracując z algorytmem PFS, po krótkim czasie zaczyna być oczywiste, że posiadanie stałej liczby punktów kontrolnych równomiernie rozmieszczonych wzdłuż krzywej sklejaney ogranicza zdolność algorytmu do dostosowania krzywej do dowolnego możliwego kształtu otaczającego środowiska. Dla dowolnie przyjętej liczby punktów kontrolnych możemy znaleźć środowisko, które jest na tyle złożone, że nie będzie aproksymowane z zadowalającą jakością. Co więcej, zwiększenie liczby punktów kontrolnych jest również ograniczone przez zasoby sprzętowe, takie jak dostępna pamięć i moc obliczeniowa. Równomiernie rozłożone punkty kontrolne jeszcze bardziej pogarszają jakość aproksymacji. W tym samym scenariuszu drogowym i w tym samym czasie w aproksymowanym środowisku mogą pojawić się zarówno złożone, jak i proste kształty. W celu osiągnięcia wysokiej dokładności aproksymacji kształtu przy zachowaniu akceptowalnie krótkiego czasu obliczeń należy zwiększyć liczbę punktów kontrolnych w otoczeniu złożonych kształtów i ograniczać ich liczbę w otoczeniu prostych kształtów. Tak więc, nawet jeśli liczba punktów kontrolnych jest stała, nadal możemy poprawić jakość aproksymacji i czas obliczeń, przenosząc niektóre punkty kontrolne do obszarów o bardziej złożonych kształtach.

W celu podjęcia decyzji gdzie liczbę punktów kontrolnych należy zwiększyć, a gdzie zmniejszyć, zaproponowano lokalną analizę kształtu krzywej. Aby przeanalizować fragment krzywej odzwierciedlający granice wolnej przestrzeni, wprowadzono lokalny wskaźnik złożoności kształtu (LSC), który opisuje lokalną złożoność krzywej w pobliżu pojedynczego punktu kontrolnego. Analiza kształtu prowadzona w oparciu o wprowadzony zestaw wskaźników złożoności krzywej, jest zdefiniowana w następujący sposób.

Wskaźnik lokalnej złożoności kształtu jest obliczany poprzez filtrację w czasie chwilowej lokalnej złożoności kształtu. Ma to na celu ograniczenie nagłych zmian jego wartości, a w konsekwencji naprzemiennego dodawania i usuwania punktów kontrolnych w jednym obszarze krzywej:

$$\begin{aligned}\Psi_{k,i} &= (1 - c_\Psi)\Psi_{k-1,i} + c_\Psi\tilde{\Psi}_{k,i} \\ k &= 1, 2, 3, 4, \dots \\ i &= 1, 2, 3, 4, \dots, N_q\end{aligned}\quad (1)$$

gdzie:

- k – indeks cyklu śledzenia (iteracja).
- i – indeks punktu kontrolnego.
- c_Ψ – współczynnik filtra.
- $\tilde{\Psi}_{k,i}$ – surowa (chwilowa) wartość złożoności kształtu i -tego punktu kontrolnego w k -tym cyklu.
- $\Psi_{k,i}$ – końcowa (przefiltrowana) wartość złożoności kształtu i -tego punktu kontrolnego w k -tym cyklu.

Chwilowa złożoność kształtu $\tilde{\Psi}_{k,i}$ jest obliczana na podstawie czterech składników w następujący sposób (indeks k został pominięty dla przejrzystości, Rysunek 2):

$$\tilde{\Psi}_i = \min(\max(f(\Delta_i, \Gamma_i, \Theta_i, \Xi_i), -1), 1) \quad (2)$$

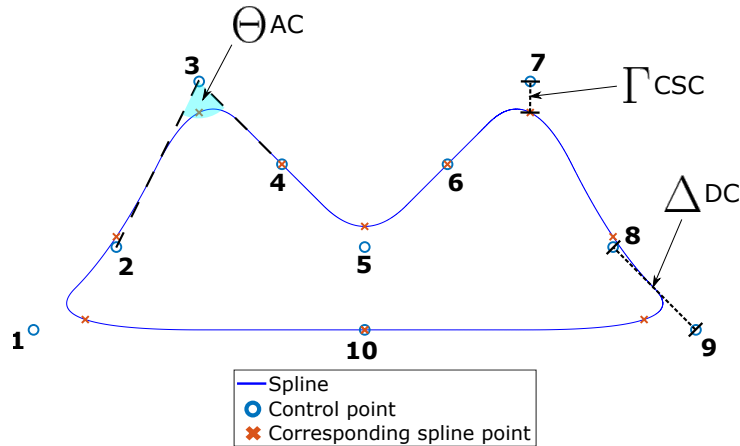
gdzie:

- Δ_i – wskaźnik złożoności odległościowej i -tego punktu kontrolnego.
- Γ_i – wskaźnik złożoności i -tego punktu kontrolnego odpowiadającego punktowi krzywej sklejaney.
- Θ_i – wskaźnik złożoności kątowej i -tego punktu kontrolnego.

Ξ_i – wskaźnik zależny od parametrów pojazdu oraz położenia i -tego punktu kontrolnego względem pojazdu.

oraz

$$f(\Delta_i, \Gamma_i, \Theta_i, \Xi_i) = \begin{cases} \Gamma_i + \Delta_i + \Xi_i & \text{for } \Gamma_i \leq 0 \\ \Theta_i \cdot \Gamma_i + \Delta_i + \Xi_i & \text{otherwise} \end{cases} \quad (3)$$

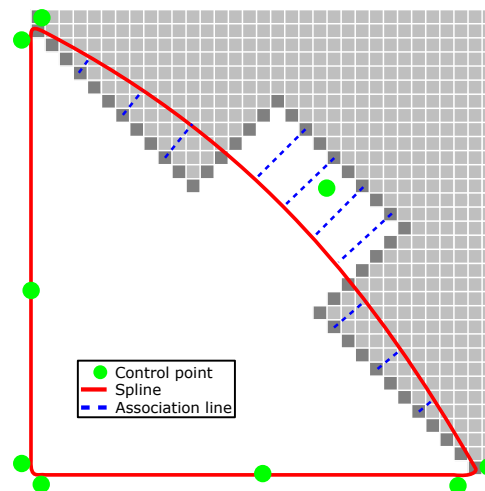


Rysunek 2. Wyjaśnienie trzech wskaźników złożoności kształtu: AC — złożoność kątowna, DC — złożoność odległościowa, CSC — złożoność punktu kontrolnego odpowiadającego punktowi krzywej sklejanej.

4.2 Rozwiązywanie problemu lokalnych minimów aproksymacji

Zaproponowany algorytm aproksymuje granice wolnej przestrzeni na podstawie dostarczonych punktów pomiarowych. Jest to proces iteracyjny w którym aproksymowany kształt zmienia się w czasie z powodu ruchu pojazdu. Algorytm może utknąć w lokalnym minimum funkcji celu (błędzie aproksymacji), jak pokazano na rysunku 3, co jest niedopuszczalne z punktu widzenia bezpieczeństwa ruchu.

W rozprawie zaproponowano wykrywanie takich sytuacji poprzez obliczanie lokalnego wskaźnika błędzie aproksymacji zdefiniowanego jak poniżej dla każdego punktu kontrolnego:



Rysunek 3. Ilustracja utknięcia algorytmu aproksymacji w lokalnym minimum.

$$\Phi_{k,i} = (1 - c_\Phi)\Phi_{k-1,i} + c_\Phi\hat{\Phi}_{k,i} \quad (4)$$

$$\check{\Phi}_{k,i} = \begin{cases} 0, & \check{\Phi}_{k,i} \leq 0 \\ \frac{\check{\Phi}_{k,i}}{\Phi_{high}}, & \check{\Phi}_{k,i} \in (0, \Phi_{high}) \\ 1, & \Phi_{high} \leq \check{\Phi}_{k,i} \end{cases} \quad (5)$$

$$\check{\Phi}_{k,i} = \begin{cases} d_i^{max} & \text{if } d_{th} < d_i^{max} \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

$$d_i^{max} = \max_j \left(\left\{ d(r(s_j), z_j) : s_j \in \check{\Lambda}_i \right\} \right) \quad (7)$$

$$\check{\Lambda}_i \subset \Lambda_i \quad (8)$$

- $\Phi_{k,i}$ – wskaźnik błędu aproksymacji punktu kontrolnego w k -tym cyklu
- $\check{\Phi}_{k,i}$ – wskaźnik surowego błędu aproksymacji punktu kontrolnego w k -tym cyklu.
- $d(a, b)$ – odległość euklidesowa między punktami a i b
- d_i^{max} – maksymalna wartość $d(a, b)$ dla i -tego punktu kontrolnego
- $\mathbf{r}(s_j)$ – j -ty punkt leżący na krzywej
- \mathbf{z}_j – j -ty punkt pomiarowy odpowiadający j -temu punktowi leżącemu na krzywej
- $\check{\Lambda}_i$ – ograniczony obszar wsparcia i -tego punktu kontrolnego. Jest to podprzedział Λ_i ograniczony symetrycznie względem środka przedziału.
- c_Φ – współczynnik filtra

4.3 Filtracja punktów pomiarowych

Liczba pomiarów dostarczanych podczas przetwarzania siatki zajętości może być znaczna. Wiele z tych pomiarów (pikseli) jest nadmiarowych. Nie wnoszą one nowej informacji i można je odrzucić z dalszego przetwarzania bez wpływu na jakość aproksymacji granicy wolnej przestrzeni. Zmniejsza to również zapotrzebowanie na pamięć i moc obliczeniową. W pracy doktorskiej zaproponowano następujące metody filtracji punktów pomiarowych:

1. uniform downselection

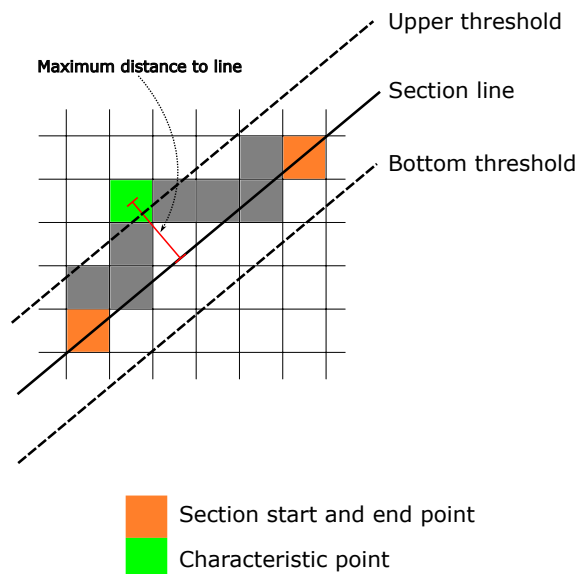
Metoda naiwnej filtracji pozostawiająca co k -ty punkt pomiarowy.

2. line downselection (Rysunek 4)

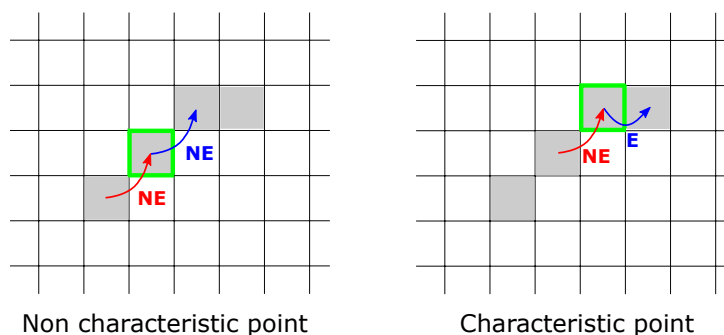
Metoda ta pomija (odrzuca) jak najwięcej współliniowych punktów pomiarowych. Koncentruje się na filtrowaniu punktów leżących w pobliżu wspólnej prostej.

3. direction downselection (Rysunek 5)

Ta metoda wyszukuje punkty charakterystyczne, podobnie jak metoda *line*. Jest ona ograniczona do podstawowych operacji na pikselach. Skupia się ona na sprawdzaniu, czy kierunek ruchu od poprzedniego piksela do piksela będącego przedmiotem zainteresowania jest taki sam jak kierunek ruchu od piksela będącego przedmiotem zainteresowania do następnego piksela.



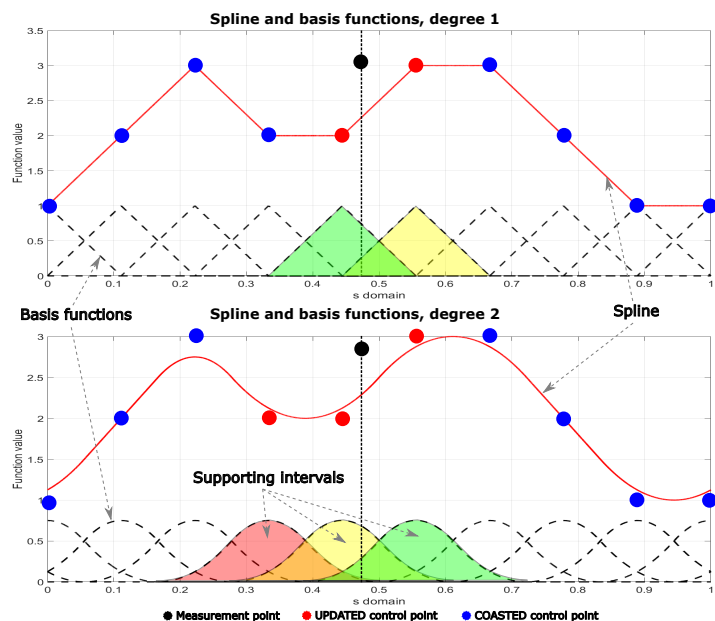
Rysunek 4. Wizualizacja metody filtracji - *line* [Szlachetka et al., 2022].



Rysunek 5. Wizualizacja metody filtracji - *direction* [Szlachetka et al., 2022].

4.4 Określanie lokalnego stanu pomiaru

Zaproponowany algorytm wykorzystuje wiedzę na temat statusu punktu kontrolnego określanego na podstawie asocjacji danych pomiarowych (Rysunek 6). Status ten zawiera w sobie wiedzę o czasie istnienia punktu kontrolnego i powiązanych z nim punktów pomiarowych. Może on przyjąć jedną z trzech możliwych wartości: NEW (punkt utworzony w ostatnim cyklu), UPDATED (punkt został ostatnio zmodyfikowany przez nowe pomiary) i COASTED (w ostatnim cyklu śledzenia punkt nie został zaktualizowany o nowe pomiary). Informacja na temat statusu wykorzystana jest podczas podejmowania decyzji o usunięciu danego punktu kontrolnego.



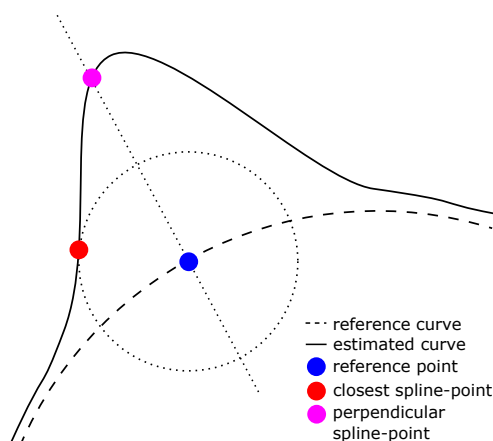
Rysunek 6. Określenie statusu punktu kontrolnego na podstawie obecności punktu pomiarowego w przedziale wsparcia punktu kontrolnego.

4.5 Metryki jakości aproksymacji

Aby ocena jakości aproksymacji z krzywą sklejaną była możliwie dokładna, stosowana jest metodologia parowania. Dla każdego punktu referencyjnego określany jest odpowiadający mu punkt leżący na krzywej (*spline point*), tworząc zestaw par co cykl śledzenia (iterację). *Spline point* może być określony jedną z dwóch metod nazwanych *closest spline point* lub *perpendicular spline point* (Rysunek 7).

Metoda *closest spline point* definiuje *spline point* jako punkt, który ma najmniejszą odległość euklidesową do punktu referencyjnego.

Metoda *perpendicular spline point* definiuje *spline point* jako punkt, który znajduje się najbliżej stycznej do krzywej referencyjnej w punkcie referencyjnym.



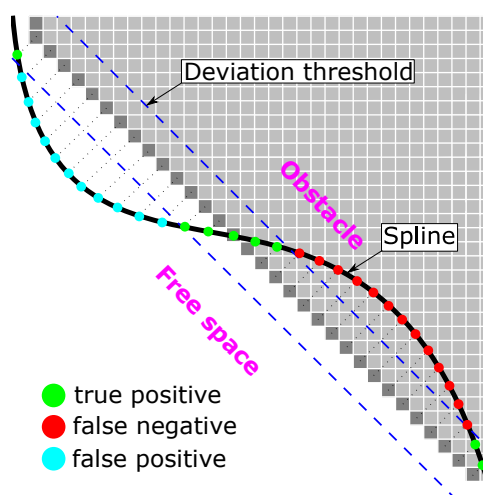
Rysunek 7. Określanie punktu krzywej sklejaney (*spline point*) z wykorzystaniem zaproponowanych metod [Szlachetka et al., 2022].

4.6 Metryki błędów detekcji

W zadaniu śledzenia granicy wolnej przestrzeni mogą wystąpić obszary, w których odchylenia estymowanej krzywej od rzeczywistej granicy wolnej przestrzeni mogą być niedopuszczalnie wysokie. W ogólnym przypadku śledzenia granic wolnej przestrzeni punkty leżące na krzywej można sklasyfikować jako prawdziwie pozytywne, fałszywie pozytywne (fałszywie reprezentują nieistniejącą przeszkodę w obszarze wolnej przestrzeni) oraz fałszywie negatywne (fałszywie wskazują na wolną przestrzeń w miejscu faktycznej przeszkody ograniczającej wolną przestrzeń), rysunek 8.

Punkty leżące blisko granicy wolnej przestrzeni, dla których odległość do krzywej referencyjnej (faktyczna granica wolnej przestrzeni) jest poniżej bezpiecznego progu klasyfikacji (np. 50 cm), nazywane są punktami prawdziwie pozytywnymi (TP *true positive*).

Punkty leżące w odległości większej niż próg klasyfikacji od krzywej referencyjnej klasyfikowane są jako błędy detekcji, które mogą należeć do dwóch klas:



Rysunek 8. Wizualizacja błędów detekcji.

Błąd typu I (FP false positive) występuje, gdy przybliżona odległość punktu leżącego na krzywej od granicy krzywej referencyjnej przekracza próg klasyfikacji, a punkt znajduje się w obszarze przestrzeni wolnej od przeszkód.

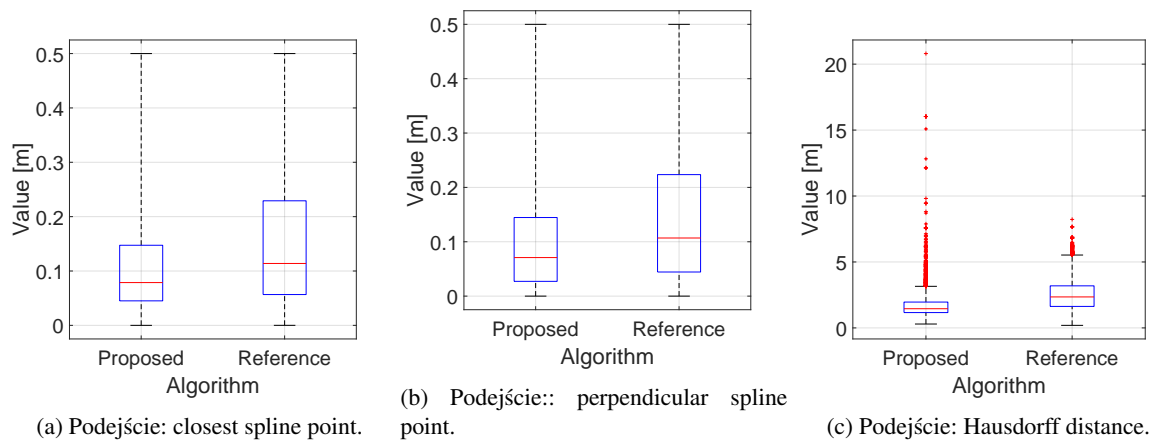
Błąd typu II (FN false negative) występuje, gdy przybliżona odległość punktu leżącego na krzywej od granicy krzywej referencyjnej przekracza próg klasyfikacji, lecz punkt znajduje się poza obszarem przestrzeni wolnej od przeszkód.

4.7 Wyniki porównania

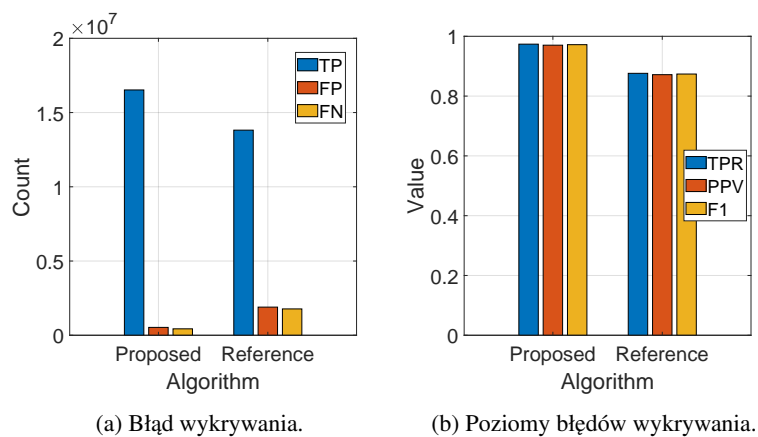
Skuteczność obu algorytmów została przeanalizowana na bazie 22 sztucznych scenariuszy i 1 rzeczywistym. Rysunek 9 przedstawia wyniki z wszystkich sztucznych scenariuszy w postaci wykresów pudełkowych. Wykresy potwierdzają, że zaproponowany algorytm osiąga lepszą jakość aproksymacji. Ogólnie rzecz biorąc, jego błąd aproksymacji jest niższy (mediana absolutnych odchyłek bezwzględnych jest o około 31%, a średnia tychże odchyłek o 28% niższa). Wykresy pudełkowe pokazane na rysunku 9c wskazują na przewagę zaproponowanego algorytmu w porównaniu z algorytmem referencyjnym.

Analiza wyników w odniesieniu do błędów detekcji również wskazuje na lepszą skuteczność zaproponowanego algorytmu (Rysunek 10). Liczba TP jest o 20% wyższa, liczba FP jest o 72% niższa, a liczba FN jest o 76% niższa.

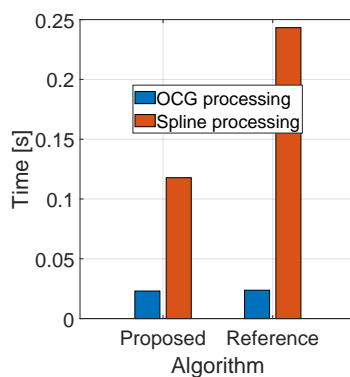
Pod względem czasu wykonania, zaproponowany algorytm jest prawie dwa razy szybszy niż algorytm referencyjny, jak pokazano na rysunku 11. Czas przetwarzania siatki zajętości nie ma wpływu na wynik, ponieważ oba algorytmy wykorzystują dokładnie ten sam algorytm przetwarzania siatki zajętości.



Rysunek 9. Wykresy pudełkowe błędów aproksymacji zagregowane ze wszystkich sztucznych scenariuszy.



Rysunek 10. Liczby i metryki błędów wykrywania zagregowane ze wszystkich sztucznych scenariuszy.



Rysunek 11. Czas wykonania algorytmów zagregowany ze wszystkich sztucznych scenariuszy.

4.8 Inne

Pozostały wkład autora w tę dziedzinę jest następujący:

- **Dostosowywanie punktów kontrolnych**
Zestaw reguł decyzyjnych służących do oceny, kiedy i gdzie dodawany jest nowy punkt kontrolny lub usuwany jest istniejący punkt kontrolny.
- **Porównanie modeli stacjonarnych**
Porównanie modeli do reprezentacji stacjonarnego środowiska pod względem zestawu ich cech i przydatności względem scenariuszy drogowych.
- **Generatory siatek zajętości**
Dwa generatory siatki (generujące siatkę binarną oraz siatkę zajętości) stworzone na potrzeby rozwoju zaproponowanego w rozprawie algorytmu i porównania z algorytmem referencyjnym.

5 Podsumowanie

W pracy przedstawiono nowy algorytm śledzenia granic wolnej przestrzeni oparty na modelu w postaci parametrycznej krzywej typu B-spline.

Zaproponowany algorytm składa się z dwóch głównych kroków tj. przetwarzania siatki zajętości i aproksymacji granic wolnej przestrzeni krzywą sklejaną. W pracy zaproponowano kilka sposobów przetwarzania punktów pomiarowych, w tym ekstrakcję oraz filtrację pomiarów czy metody wyszukiwania punktu na krzywej odpowiadającego punktowi pomiarowemu. Zaproponowany algorytm został wzbogacony o dynamiczny dobór liczby i położenia punktów kontrolnych krzywej sklejaney. Decyzje o dodaniu lub usunięciu punktu kontrolnego podejmowane są m.in. w oparciu o analizę lokalnej złożoności kształtu krzywej, która wykorzystuje lokalne wskaźniki złożoności kształtu zaproponowane przez autora. Dodatkowo, aby rozwiązać problem lokalnych minimów, wprowadzono wskaźnik błędu aproksymacji.

W końcowej części pracy doktorskiej przeprowadzone zostały testy i weryfikacja zaproponowanego algorytmu. Odbyna się to poprzez porównanie zaproponowanego algorytmu z wybranym algorytmem referencyjnym (PFS). Porównanie przeprowadzone jest głównie na sztucznych danych z wykorzystaniem metryk takich jak odległość Hausdorffa oraz dwóch zaproponowanych przez autora metryk pomiaru błędu aproksymacji.

Analiza porównawcza dowodzi, że zaproponowany algorytm jest lepszy pod względem jakości aproksymacji (we wszystkich zastosowanych metrykach) jak i czasu wykonania.

6 Wykaz publikacji i osiągnięć autora

Opublikowane:

- **Marek Szlachetka**, Dariusz Borkowski, Jarosław Wąs.
Stationary environment models for Advanced Driver Assistance Systems
2020 Signal Processing: Algorithms, Architectures, Arrangements, and Applications doi:
10.23919/SPA50552.2020.9241306
- **Marek Szlachetka**, Dariusz Borkowski, Jarosław Wąs.
The downselection of measurements used for free space determination in ADAS
Journal of Computational Science, Volume 63, 2022, 101762, ISSN 1877-7503, doi:
10.1016/j.jocs.2022.101762
- Jarosław Wąs, Dariusz Pałka, Grzegorz Bazior, Robert Lubaś, Michał Turek, Paweł Renc, **Marek Szlachetka**, inni.
Modelowanie systemów złożonych w teorii i praktyce
doi: 10.7494/978-83-66727-89-2_7

W trakcie recenzji:

- **Marek Szlachetka**, Dariusz Borkowski, Jarosław Wąs.
B-Spline control point adjustment based on local curve complexity for free space determination in Advanced Driver Assistance Systems
Expert Systems With Applications,
URL <https://track.authorhub.elsevier.com/?uuiid=56fdf072-e8a7-48d3-bb4b-7669d36107d3>

Patenty:

- **Marek Szlachetka**, Kamil Ostrowski
Methods and systems for tracking an object
numer US2021339750A1 / EP 3904907 A1
- **Marek Szlachetka**, Dariusz Borkowski
Method for determination of a free space boundary of a physical environment in a vehicle assistance system
numer EP22186229.5
- **Marek Szlachetka**, Dariusz Borkowski
Method for resolution of local minima in determinations of a free space boundary in a vehicle assistance system
numer US 63/500,096
- **Marek Szlachetka**, Dariusz Borkowski
Method for associating measurement points to spline points in determinations of a free space boundary in a vehicle assistance system
numer US 63/500,092

7 Bibliografia

M. Szlachetka, D. Borkowski, and J. Waś. The downselection of measurements used for free space determination in adas. *Journal of Computational Science*, 63:101762, 2022.