

AKADEMIA GÓRNICZO-HUTNICZA
IM. STANISŁAWA STASZICA
WYDZIAŁ ELEKTROTECHNIKI, AUTOMATYKI, INFORMATYKI I ELEKTRONIKI
Katedra Informatyki

UNIVERSITÉ DE TECHNOLOGIE DE BELFORT-MONTBÉLIARD
Laboratoire Systèmes et Transports

AUTOREFERAT PRACY DOKTORSKIEJ

ZASTOSOWANIE FUZJI WIELOSENSORYCZNEJ DO CELOW
REPREZENTACJI I ŚLEDZENIA OBIETKÓW DYNAMICZNYCH.

Mgr inż. Paweł Kmiotek

Promotorzy:
Prof. Yassine Ruichek
Prof. AGH dr hab. inż. Krzysztof Cetnarowicz

Kraków, 2009


1 Wstęp

Temat niniejszej pracy związany jest bezpośrednio z projektem "Pojazdy inteligentne i ich integracja w mieście przyszłości", prowadzonym przez Laboratorium Systemów i Transportu na Uniwersytecie Technicznym Belfort-Montbéliard we Francji. Celem tego projektu jest stworzenie systemu nawigacji autonomicznej pojazdów w środowisku miejskim.

Konieczność realizacji tego projektu podyktowana jest głównie aspektami związanymi z poprawą bezpieczeństwa i komfortu oraz obniżeniem kosztów transportu. Instalacja pasywnych systemów bezpieczeństwa, takich jak: pasy bezpieczeństwa, poduszki powietrzne, kontrolowane strefy zgniotu czy systemy ochrony przechodniów, powoduje znaczne zmniejszenie ilości zgonów w wypadkach samochodowych. Dalszy wzrost bezpieczeństwa możliwy będzie dzięki użyciu aktywnych systemów takich jak: systemu unikania kolizji (ang. Collision Avoidance), układu przygotowującego do zderzenia (ang. Pre-crash) czy aktywnej kontroli prędkości (ang. Active Cruise Control).

System autonomicznej nawigacji pojazdu może być podzielony na trzy podsystemy. Pierwszy z nich związany jest z postrzeganiem otoczenia i składa się z detekcji przejezdnych obszarów (wyróżniając drogi, jezdnie, przeszkody), śledzenia dynamicznych obiektów oraz rozpoznawania pionowych i poziomych znaków drogowych. Celem drugiego podsystemu jest lokalizacja pojazdu w środowisku. Trzeci podsystem odpowiedzialny jest za wyznaczanie drogi do celu, biorąc pod uwagę informacje o otoczeniu uzyskane w dwóch pierwszych podsystemach.

Rysunek 1 przedstawia schematyczną budowę systemu śledzenia obiektów. Informacje na temat otoczenia zbierane są w procesie percepcji, wykorzystując dostępne sensory. W zależności od rodzaju danych i użytych dalej algorytmów surowe dane (ang. raw data) sensoryczne muszą być wstępnie przetworzone. Następnym etapem jest detekcja obiektów i klasteryzacja danych. Klasteryzacja może być również postrzegana jako etap wstępny asocjacji danych. W etapie asocjacji danych następuje "powiązanie" danych sensorycznych ze śledzonymi obiektami, które w systemie reprezentowane są przez ślady (ang. track) oraz ewentualne wyekstrahowanie prymitywu będącego pomiarem (ang. measurement) stanu obiektu w danym momencie. Na podstawie pomiarów proces filtracji dostarcza estymacji stanu obiektu.



Rysunek 1: Schematyczna reprezentacja systemu śledzenia obiektów ruchomych.

Niniejsza praca doktorska koncentruje się na postrzeganiu otoczenia, w szczególności na śledzeniu obiektów ruchomych, wykorzystując dane wielosensoryczne. Celami tego zadania jest detekcja oraz estymacja stanu obiektów dynamicznych. W ramach problematyki śledzenia obiektów ruchomych można wyróżnić: reprezentacje obiektów, asocjacje danych oraz estymacje stanu obiektów. Wybór odpowiedniego modelu reprezentacji obiektów jest istotną kwestią, gdyż model powinien zachować odpowiednie proporcje pomiędzy dokładnością reprezentacji a złożonością obliczeniową. Poza tym metody asocjacji danych oraz estymacji są bezpośrednio związane z wybranym modelem reprezentacji obiektów. Kolejnym ważnym elementem systemu percepcji jest proces asocjacji danych. Błędne powiązanie danych sensorycznych z obiektami powoduje złą estymację stanu obiektów. W zadaniu śledzenia estymacja stanu obiektu często zwana filtracją, jest rekurencyjnym procesem, który oszacowuje stan śledzonych obiektów, mając do dyspozycji dane obarczone błędami. Postrzeganie otoczenia możliwe jest dzięki zastosowaniu dwuwymiarowego skanera laserowego oraz sensora stereowizyjnego.

Teza pracy:

Poprawa niezawodności systemu śledzenia obiektów dynamicznych poprzez użycie: modelu reprezentacji obiektów opartego na zorientowanym prostokącie ograniczającym (OBB - ang. Oriented Bounding Box) niebazującym na założeniu planarności postrzeganych powierzchni, niepewności międzypromiennej (IR - ang. Inter-Rays uncertainty), założenia o niezmienności rozmiaru śledzonych obiektów (FS - ang. Fixed Size assumption), algorytmu fuzji danych pochodzących z dwóch skanerów laserowych, algorytmu asocjacji danych opartego na metodzie najbliższego sąsiada (NN - ang. Nearest Neighbor) i na założeniu o niezmienności rozmiaru śledzonych obiektów oraz algorytmu klasteryzacji danych skanera laserowego z wykorzystaniem stereowizji.

2 Platformy testowe

W celach weryfikacji skuteczności opracowanych algorytmów w ramach pracy powstał symulator, umożliwiający testowanie różnych konfiguracji sensorów, biorący pod uwagę ich położenie na pojeździe jak i ich parametry. Rysunek 2(a) przedstawia zrzut ekranu z symulatora. W ramach symulatora możliwe są:

- wizualizacja świata 3D,
- symulacja dynamiki obiektów,
- symulacja sensorów takich jak; dwu- i trójwymiarowy skaner laserowy wraz z symulacją błędów pomiarowych, mono- i stereowizję oraz drogomierz,
- konstrukcja światów 3D przez wykorzystanie gotowych modeli,
- tworzenie ścieżek, którymi podążają śledzone obiekty.

Dodatkowo algorytmy przetestowane zostały na rzeczywistych danych. Dane te zostały zebrane przy pomocy eksperymentalnej platformy badawczej (patrz Rysunek 2(b)). Na elektrycznym pojeździe, będącym podstawą platformy, umieszczone są sensory, umożliwiające między innymi percepcje otoczenia. Wśród nich można wyróżnić: dwuwymiarowy skaner laserowy SICK LMS 221, trójwymiarowy skaner laserowy Ibeo LUX oraz kamerę stereowizyjną Bumblebee 2. Do weryfikacji poprawności otrzymanych wyników posłużył sensor GPS-RTK, charakteryzujący się dokładnością pomiaru pozycji rzędu jednego centymetra.

3 Reprezentacja obiektów

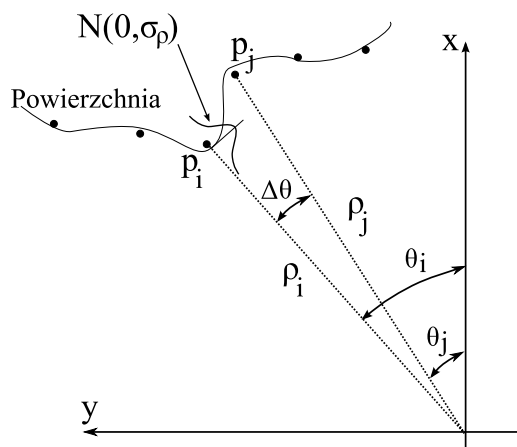
W procesie śledzenia dla każdego wykrytego obiektu tworzy się tak zwany ślad (ang. track), który jest wyestymowanym wektorem stanu obiektu w danej chwili. Estymacja przeprowadzana jest przy pomocy Rozszerzonego Filtru Kalmana (ang. Extended Kalman Filter) bazując na pomiarach stanu danego obiektu. Pomiarom stanu obiektu mogą być bezpośrednio surowe dane sensoryczne (ang. raw data) lub wyekstrahowany z nich prymityw. Model reprezentacji obiektu definiuje, w jaki sposób śledzony obiekt reprezentowany jest w systemie oraz definiuje sposób uzyskania pomiaru stanu obiektu z surowych danych sensorycznych.

Surowe dane skanera laserowego mają postać serii punktów. Punkt p_i w lokalnym układzie współrzędnych sensora opisany jest kątem orientacji oraz odległością (θ_i, ρ_i) (patrz Rysunek 3). Pomiar odległości obarczony jest błędem o rozkładzie normalnym $N(0, \sigma_\rho)$.

Biorąc pod uwagę problem śledzenia ruchomych obiektów, reprezentacja obiektów oparta na zorientowanym prostokącie ograniczającym (ang. Oriented Bounding Box) ma następujące zalety:



Rysunek 2: (a) Symulator, (b) Eksperymentalna platforma badawcza.



Rysunek 3: Pomiar odległości przy pomocy skanera laserowego.

- aproksymacja kształtu i dzięki temu określenie zajmowanej powierzchni,
- wystarczająca precyzja,
- łatwość określenia niepewności położenia obiektu,
- intuicyjne i łatwe użycie,
- kompresja danych.

Algorytmny ekstrakcji zorientowanych prostokątów spotykane w literaturze zakładają, że śledzone obiekty mają kształt prostokątny w rzucie poziomym. Algorytm zaprezentowany w pracy nie jest oparty na tym założeniu, dzięki temu może być zastosowany dla obiektów mających inne kształty.

Pomiar stanu obiektu jest opisany wektorem z , którego elementy określają położenie środka obiektu cx , cy , kąt orientacji α oraz rozmiar dx , dy w lokalnym układzie współrzędnych związanym z platformą, z której postrzegane jest otoczenie. Niepewność pomiaru opisana jest wektorem σ_z .

$$z = [cx, cy, \alpha, dx, dy]^T \quad (1)$$

$$\sigma_z = [\sigma_{cx}, \sigma_{cy}, \sigma_\alpha, \sigma_{dx}, \sigma_{dy}]^T \quad (2)$$

Ślad obiektu określony jest wektorami stanu x oraz niepewności σ_x . Wektory te, oprócz informacji zawartej w wektorach pomiaru stanu obiektu, zawierają estymację prędkości liniowej $\dot{c}x$, $\dot{c}y$ oraz kątovej $\dot{\alpha}$.


$$x = [cx, \dot{c}x, cy, \dot{c}y, \alpha, \dot{\alpha}, dx, dy]^T \quad (3)$$

$$\sigma_x = [\sigma_{cx}, \sigma_{\dot{c}x}, \sigma_{cy}, \sigma_{\dot{c}y}, \sigma_\alpha, \sigma_{\dot{\alpha}}, \sigma_{dx}, \sigma_{dy}]^T \quad (4)$$

Zaproponowany w pracy algorytm ekstrahowania zorientowanego prostokąta ograniczającego oparty jest na algorytmie Rotating Callipers (RC) [1]. Algorytm ten znajduje najlepiej dopasowany prostokąt ograniczający dla otoczki wypukłej zbudowanej dla punktów pomiarowych powiązanych z danym obiektem. W związku z tym, że dane ze skanera laserowego dotyczą tylko widocznej części obiektu, tworzy się niedomkniętą otoczkę wypukłą.

3.1 Tworzenie otoczki wypukłej dla punktów pomiarowych

Zaproponowano dwa algorytmy do tworzenia otoczki wypukłej dla surowych danych skanera laserowego. Pierwszy algorytm bazuje na fakcie, że punkty pomiarowe pojawiają się sekwencyjnie. Dzięki temu algorytm nie potrzebuje wszystkich punktów pomiarowych, by stworzyć otoczkę lecz uaktualnia już stworzoną otoczkę, dodając nowe punkty pomiarowe. Dodanie każdego punktu wiąże się z przeprowadzeniem testu wypukłości dla całej otoczki. W każdej iteracji testu sprawdzana jest relacja geometryczna nowego punktu, dwóch ostatnich punktów z otoczki oraz początku układu współrzędnych. Na rysunku 4 przedstawione są sytuacje, gdy warunek wypukłości jest spełniony (a) oraz gdy nie jest spełniony (b), gdzie N jest nowym punktem, A i B są dwoma ostatnimi punktami w otoczce, O jest środkiem układu współrzędnych sensora.




Rysunek 4: Konstrukcja otoczki wypukłej - test wypukłości: (a) warunek wypukłości jest spełniony, (b) warunek wypukłości nie jest spełniony.

Drugi algorytm oparty jest na algorytmie Line Tracking [2], służącym do segmentacji punktów tzn. dopasowaniu odcinków do podanych punktów. Przy czym ilość odcinków wyznaczana jest automatycznie na podstawie detekcji punktów załamania (ang. break point). W tym podejściu punkty otoczki definiowane są przez punkty przecięcia się linii uzyskanych przez algorytm Line Tracking.

Do uzyskania poprawnej orientacji danego prostokąta ograniczającego dla danego obiektu, algorytm RC musi operować na domkniętej otoczce wypukłej. Bazując na założeniu, że części widoczne i

niewidoczne są symetryczne względem punktu symetrii, będącego środkiem odcinka łączącego pierwszy i ostatni punkt niedomkniętej otoczki wypukłej, tworzy się zamkniętą otoczkę wypukłą. Założenie symetrii umożliwia uzyskanie poprawnej orientacji prostokąta ograniczającego przez algorytm RC.



Rysunek 5: Otoczką wypukłą oraz wizualizacja działania algorytmu Rotating Callipers.

Algorytm RC bazuje na twierdzeniu, że najlepiej dopasowany do punktów zorientowany prostokąt ograniczający ma co najmniej jeden bok współliniowy z co najmniej jednym z boków otoczki wypukłej, utworzonej dla danych punktów (bok $P1-P2$ na rysunku 5). Najlepiej dopasowany zorientowany prostokąt ograniczający charakteryzuje się najmniejszą powierzchnią z wszystkich możliwych prostokątów ograniczających. W związku z tym, w algorytmie wyznacza się prostokąt o najmniejszej powierzchni z tych, które mają co najmniej jeden bok współliniowy z otoczką wypukłą.

W pierwszym kroku algorytmu wyznacza się prostokąt mający co najmniej jeden bok współliniowy z otoczką wypukłą. W każdym następnym kroku następuje obrócenie prostokąta o minimalny kąt w taki sposób, by uzyskać współliniowość następnego boku w otoczce z bokiem prostokąta. Algorytm kończy się, gdy prostokąt został obrócony o kąt prosty.

Niepewność orientacji dokonanego pomiaru uzyskano przy pomocy algorytmu regresji liniowej dla danych w biegunowym układzie współrzędnych zaadaptowanego do danych skanera laserowego [3]. Algorytm ten uruchomiony jest dla punktów należących do boku otoczki wypukłej, który jest współliniowy z najlepiej dopasowanym zorientowanym prostokątem ograniczającym. Niepewność wielkości oraz położenia obliczone są na podstawie niepewności pomiaru skrajnych punktów prostokąta ograniczającego po zastosowaniu prawa przenoszenia błędów.

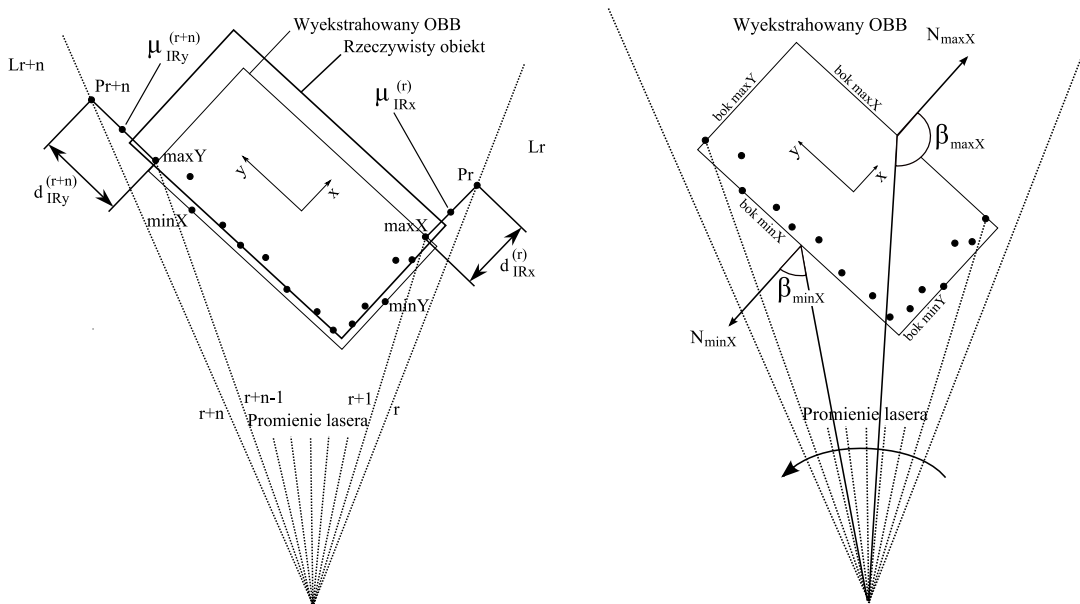
Porównanie obydwu podejść wyznaczania zorientowanego prostokąta ograniczającego wykazało, że uzyskane wyniki są porównywalne, przy czym pierwszy z nich ma mniejszą złożoność obliczeniową.

3.2 Niepewność międzypromieniowa (IR ang. Inter-Rays uncertainty)

Ważną kwestią związaną z ekstrahowaniem zorientowanego prostokąta ograniczającego jest to, że skrajne punkty prostokąta nie reprezentują punktów krańcowych prawdziwego obiektu. Wzięcie pod uwagę tej kwestii w algorytmie IR (Inter-Rays) umożliwia lepszą estymację wielkości i położenia śle-

dzanego obiektu.

Dla wyjaśnienia powyższej kwestii posłużmy się rysunkiem 6(a) biorąc pod uwagę oś X lokalnego układu współrzędnych. Punkt krańcowy śledzonego obiektu położony jest między skrajnym punktem $maxX$ prostokąta ograniczającego a punktem P_r . Jest on (P_r) punktem przecięcia się promienia lasera L_r , który nie dostarczył pomiaru odległości dla tego obiektu a prostą prostopadłą do boku prostokąta ograniczającego, do którego należy punkt $maxX$ i przechodzącą przez ten punkt skrajny. Odległość pomiędzy punktami $maxX$ oraz P_r nazywana jest dalej odległością międzypromieniową d_{IRx} . Odległość międzypromieniowa dla danej osi lokalnego układu współrzędnych obliczana jest dla boku niewidocznego oraz dla boku widocznego po uwzględnieniu stopnia jego widoczności i jest odwrotnie proporcjonalna do współczynnika widoczności dla danego boku. Stopień widoczności danego boku związany jest z kątem widoczności określonym pomiędzy normalną danego boku a prostą przechodzącą przez środek układu współrzędnych sensora i środek boku (patrz Rysunek 6(b)). Powyżej pewnej wartości granicznej, bok traktowany jest jako zupełnie widoczny i współczynnik widoczności przyjmuje wartość 1. Poniżej wartości granicznej współczynnik obliczany jest na podstawie funkcji expotencjalnej, gdzie parametrem jest kąt widoczności danego boku.



Rysunek 6: (a) Niepewność międzypromieniowa, (b) Stopień widoczności boku.

Położenie punktu krańcowego śledzonego obiektu jest opisane rozkładem jednostajnym o wartości oczekiwanej równej $\mu_{IRx}^{(r)}$ na przedziale określanym przez punkty $maxX$ oraz P_r . Uzyskana estymacja położenia krańcowego punktu śledzonego obiektu używana jest do estymacji wielkości obiektu, przy czym użyty rozkład jednostajny aproksymowany jest przez rozkład normalny, jest to związane z założeniami Filtru Kalmana.

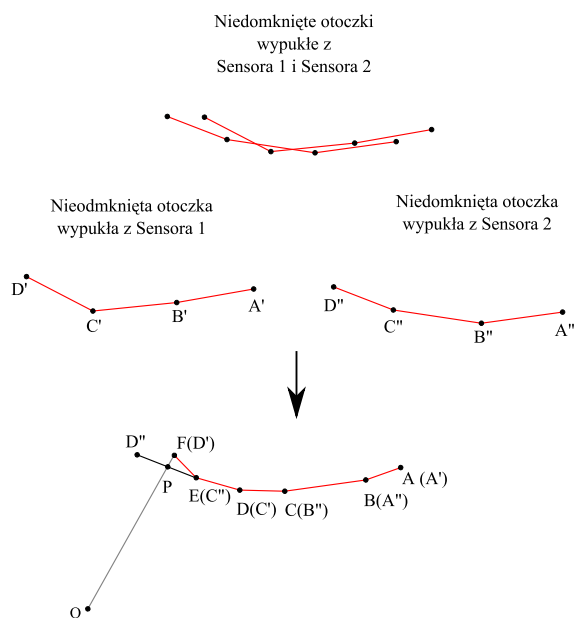
3.3 Założenie o niezmienności rozmiaru obiektu (FS ang. Fixed Size assumption)

Założenie o niezmienności rozmiaru obiektu oparte jest na fakcie, że śledzone obiekty nie zmieniają swoich rozmiarów w czasie trwania śledzenia. Jednak w związku ze zmianą wzajemnego położenia i orientacji obiektu względem sensora, zmierzona wielkość obiektu zmienia się w czasie. Głównym celem algorytmu FS (Fixed Size) jest zachowanie najlepszego, pod względem wiarygodności, pomiaru

wielkości obiektu otrzymanego w czasie śledzenia. Algorytm ten bazuje na wartości niepewności międzypromieniowej. W czasie trwania śledzenia obiektu algorytm maksymalizuje zmierzony rozmiar oraz minimalizuje niepewność międzypromieniową. Następnie estymacja rozmiaru obiektu uzyskiwana jest w taki sam sposób jak w przypadku algorytmu IR.

4 Fuzja danych pochodzących z dwóch skanerów laserowych

Zaproponowana metoda ekstrakcji zorientowanych prostokątów ograniczających działa dobrze w momencie, gdy dla danego obiektu mamy odpowiednią ilość punktów pomiarowych. Dla danego obiektu ilość uzyskanych punktów pomiarowych jest odwrotnie proporcjonalna do jego odległości od sensora i dlatego wraz ze wzrostem odległości spada jakość oszacowania stanu obiektu. Aby zaradzić takiej sytuacji zaproponowano użycie dwóch skanerów laserowych oraz przedstawiono metodę fuzji danych zaadaptowaną do użytego modelu reprezentacji obiektów. Dzięki zastosowaniu dwóch sensorów możliwe jest zwiększenie rozdzielczości kątowej pomiarów, a co za tym idzie zwiększenie ilości punktów pomiarowych dla śledzonych obiektów. Działanie algorytmu przedstawione jest schematycznie na rysunku 7. Pierwszym etapem algorytmu jest uzyskanie osobno dla każdego z sensorów niedomkniętych otoczek wypukłych dla punktów pochodzących ze śledzonego obiektu. Następnie korzystając z faktu, że punkty w otoczkach wypukłych posortowane są ze względu na kąt orientacji, następuje etap scalania otoczek. Działanie algorytmu scalania oparte jest na pierwszym z zaproponowanych algorytmów tworzenia otoczek wypukłych. W tym wypadku jednak punkty wejściowe pobierane są z otoczek wypukłych stworzonych dla poszczególnych sensorów. Odległości międzypromieniowe oblicza się na zasadzie podanej wcześniej, z tą różnicą, że do obliczeń bierze się najbliższy promień lasera, który nie dostarczył pomiaru odległości dla obiektu z obydwu sensorów.

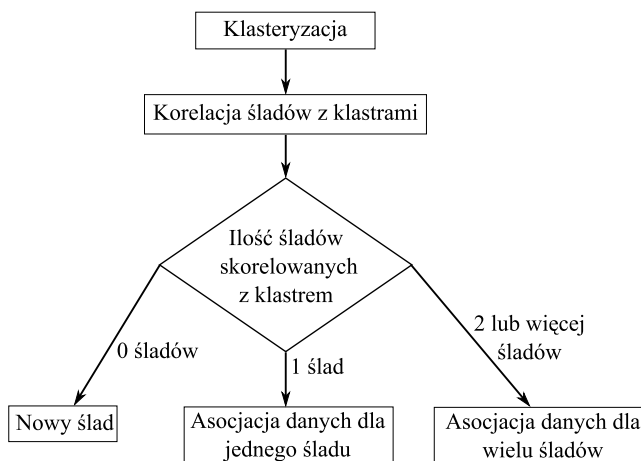


Rysunek 7: Łączenie dwóch niedomkniętych otoczek wypukłych.

5 Asocjacja danych

Proces asocjacji danych przedstawiony jest na rysunku 8. Pierwszym etapem jest klasteryzacja punktów pomiarowych skanera laserowego. Klasteryzacja jest traktowana jako przetworzenie wstępne danych w celu ich późniejszego powiązania ze śladami obiektów. Głównym celem klasteryzacji jest podzielenie problemu asocjacji na podproblemy grupując punkty w klastrach. Klasteryzacja oparta jest na metodzie odległościowej. Punkt przyłączany jest do klastra, jeżeli odległość między nim a jakimkolwiek punktem będącym członkiem klastra jest mniejsza niż wartość progu. W dalszej części opisana jest metoda klasteryzacji wykorzystująca dane stereowizyjne.

W drugim etapie następuje korelacja istniejących śladów obiektów z uzyskanymi w pierwszym etapie klastrami. W zależności od ilości śladów skorelowanych z jednym klastrzem, uruchamiana jest odpowiednia funkcja asocjacji danych. Są trzy możliwości: tworzony jest nowy ślad, następuje asocjacja punktów pomiarowych z pojedynczym śladem lub uruchamiany jest algorytm asocjacji punktów pomiaru z wieloma śladami. W pierwszym przypadku wszystkie punkty zawarte w klastrze są użyte do stworzenia nowego śladu. W drugim przypadku punkty znajdujące się w obszarze walidacyjnym śladu zostają powiązane z tym śladem. Punkty znajdujące się poza obszarem walidacyjnym podlegają kolejnemu grupowaniu i każda grupa punktów tworzy nowy ślad. Obszar walidacyjny jest to obszar określony przez największą akceptowalną odległość punktu od predykcji śladu. W trzecim przypadku uruchamiany jest algorytm oparty na metodzie najbliższego sąsiada i wykorzystujący wielkość śladu wyestymowaną przy pomocy algorytmu FS.



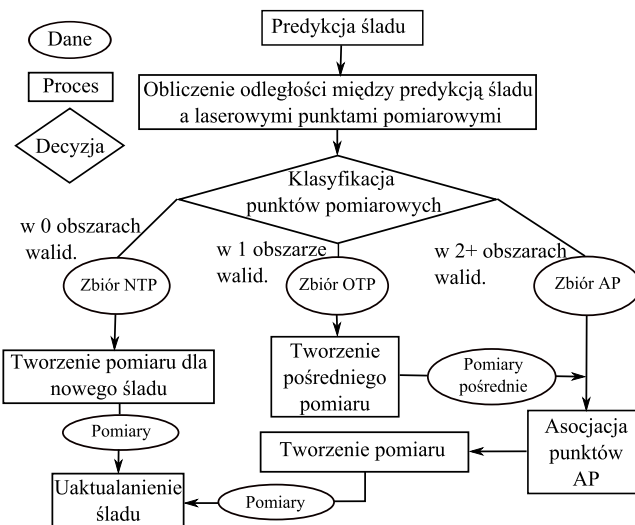
Rysunek 8: Schemat procesu asocjacji danych.

5.1 Metoda najbliższego sąsiada wraz z założeniem o niezmienności wielkości obiektu.


W standardowej wersji metoda najbliższego sąsiada uruchamiana jest dla każdego śladu w celu powiązania z nim najbliższego z dostępnych pomiarów. W tym wypadku metoda najbliższego sąsiada wykonywana jest dla każdego punktu pomiarowego w celu powiązania z najbliższym, w sensie statystycznym, śladem obiektu. Rysunek 9 przedstawia schemat proponowanego algorytmu (NNFS - ang. Nearest Neighbour Fixed Size). Danymi wejściowymi algorytmu są punkty należące do jednego klastra oraz ślady z nim skorelowane. Pierwszym etapem jest klasyfikacja punktów pomiarowych oraz umieszczenie ich w zbiorach, przy czym istnieją trzy klasy punktów, natomiast może istnieć więcej niż jeden zbiór danej klasy. Pierwsza klasa (NTP ang. New Tracks Points) to punkty nie znajdujące się w żadnym z obszarów walidacyjnych (patrz Rysunek 10). Dla każdego śladu i na podstawie jego predykcji

budowany jest jeden obszar walidacyjny. Drugą klasę (OTP ang. One Track Points) stanowią punkty znajdujące się w jednym obszarze walidacyjnym. Z każdym zbiorem tego typu powiązany jest jeden ślad obiektu. Trzecia klasa (AP ang. Ambiguous Points) składa się z punktów należących do więcej niż jednego obszaru walidacyjnego. W tym przypadku, z każdym zbiorem tego typu powiązanych jest kilka śladów, tych, których obszary walidacyjne przecinały się. Obecność punktu pomiarowego w obszarze walidacyjnym danego śladu obiektu oznacza prawdopodobieństwo, że dany punkt pochodzi od tego obiektu. Punkty, znajdujące się w zbiorze NTP, poddawane są ponownej klasteryzacji i każdy klastery tworzy nowy ślad. Z punktów, należących do zbiorów typu OTP, formowane są pośrednie pomiary stanu obiektu. W ostatnim etapie algorytmu każdy ze zbiorów typu AP jest przetwarzany osobno. Celem przetwarzania jest przyporządkowanie punktów zawartych w zbiorze do pośrednich pomiarów stanu dla śladów powiązanych z przetwarzanym zbiorem. Aby dokonać przyporządkowania, dla każdej pary (punkt, ślad) tworzony jest tymczasowy pomiar stanu obiektu. Jeśli rozmiar tymczasowego pomiaru stanu obiektu nie jest większy od predykcji śladu, to dany punkt pomiarowy może być powiązany z danym śladem. Jeśli dany punkt może być powiązany do obydwu śladów, to ostatecznie zostaje powiązany ze śladem, który jest bliżej w sensie statystycznym.

Tworzenie pomiarów stanu obiektu dokonywane jest z wykorzystaniem zaproponowanej metody ekstrahowania zorientowanych prostokątów ograniczających.




Rysunek 9: Schemat algorytmu NNFS.



Rysunek 10: Klasyfikacja punktów pomiarowych.

5.2 Klasteryzacja punktów pomiarowych z wykorzystaniem fuzji skanera laserowego i stereowizji.

Klasteryzacja bazująca na metodzie odległościowej z użyciem stałego progu nie daje możliwości poprawnego grupowania punktów pomiarowych we wszystkich sytuacjach spotykanych w środowisku drogowym. Przykład konfiguracji punktów, która sprawia trudność przedstawiona jest na rysunku 11(b). Na rysunkach 11(c) i 11(d) widać możliwą interpretację ułożenia punktów. W literaturze spotyka się metody adaptacyjne dotyczące metody klasteryzacji danych skanerów laserowych. Adaptacji podlega próg, którego wartość wyliczana jest różnymi metodami, w zależności od położenia i/lub orientacji obserwowanej powierzchni w stosunku do sensora. Podejścia te jednak nie gwarantują poprawnej asocjacji, gdyż bazują tylko na danych ze skanera laserowego i w związku z tym nie mają informacji o ewentualnej powierzchni łączącej dwa punkty. Aby rozwiązać ten problem zaproponowano metodę, która poprzez wykorzystanie informacji stereowizyjnej (informacja o głębi) umożliwia poprawne grupowanie w dwuznacznych konfiguracjach punktów pomiarowych. Dzięki analizie obrazu stereowizyjnego tylko w wybranym obszarze możliwe jest wykonanie algorytmu w czasie rzeczywistym.

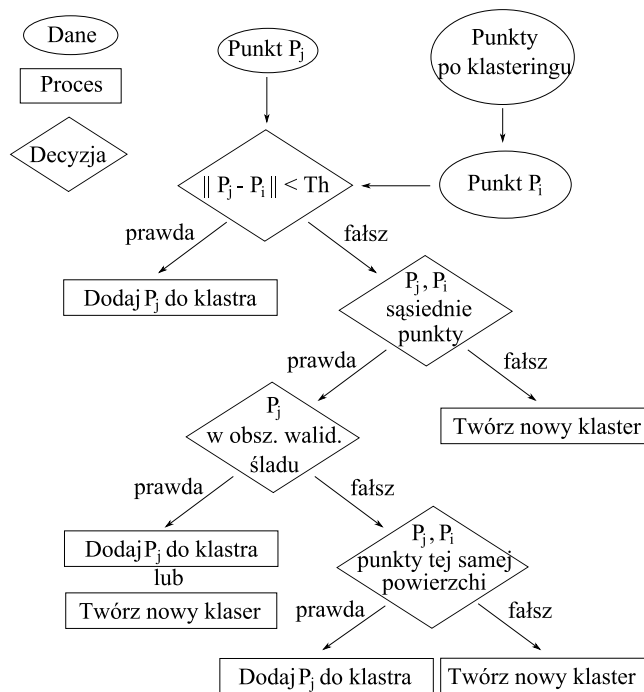


Rysunek 11: Przykład dwuznacznej konfiguracji punktów pomiarowych.

Rysunek 12 przedstawia schematycznie algorytm klasteryzacji z użyciem stereowizji. Schemat przedstawia jedną iterację algorytmu dla pary punktów P_j oraz P_i . Pierwszym etapem jest obliczenie odległości między punktami. Jeśli jest ona mniejsza niż pewna wartość progowa, punkt wejściowy P_j zostaje dodany do klastra, do którego należy punkt P_i . W przeciwnym wypadku sprawdzane jest, czy punkty P_j oraz P_i są punktami sąsiadującymi (wygenerowanymi przez sąsiadujące promienie laserowe). Jeśli nie są punktami sąsiadującymi punkt wejściowy tworzy nowy klaster. Jeśli są punktami sąsiadującymi sprawdzane jest czy punkt wejściowy P_j znajduje się w obszarze walidacyjnym, któregoś ze śladów. Jeśli tak to punkt tworzy nowy klaster lub zostaje dodany do istniejącego klastra skorelowanego ze śladem. W przeciwnym wypadku stereowizja używana jest do sprawdzenia czy hipoteza, że punkty P_i i P_j należą do tej samej powierzchni jest prawdziwa.

Wydobycie informacji o głębi z obrazów stereoskopowych składa się z dwóch podstawowych etapów. Pierwszy etap - Korelacja Stereoskopowa jest parowaniem elementów z dwóch obrazów. Drugi etap polega na obliczeniu informacji o głębi przy pomocy geometrycznej triangulacji dla sparowanych elementów.

W literaturze istnieje wiele różnych podejść do korelacji stereoskopowej. W pracy wykorzystana została metoda ZSAD (ang. Zero mean Sum of Absolute Differences). Metoda ta operuje na elementach będących pikselami obrazów i w związku z tym produkuje gęstą mapę różnic (ang. disparity map). Mapa różnic jest zbiorem różnic współrzędnych położenia sparowanych elementów (lewego i pra-




Rysunek 12: Schemat klasteryzacji.

wego). Metoda jest mniej wrażliwa przy zmianach luminescencji niż inne metody tego typu. Dla każdego piksela z obrazu, okno korelacji zawierające dany piksel oraz jego sąsiedztwo używane jest do znalezienia podobieństwa. Piksele, dla których podobieństwo jest największe zostają sparowane. Na podstawie parowania obliczana jest różnica we współrzędnych sparowanych pikseli. Rysunek 13(góra) przedstawia dwie różne sytuacje drogowe i wyznaczone dla nich mapy różnic współrzędnych położenia (środek i dół), przy czym rysunek 13(środek) przedstawia wartości bezwzględne różnic, natomiast na rysunku 13(dół) pokazane jest etykietowanie pikseli mających tę samą wartość różnicy. Jak wcześniej wspomniano analiza obrazu stereo odbywa się tylko w wybranym obszarze. Obszar ten definiowany jest poprzez projekcje na obrazy dwóch laserowych punktów pomiarowych, dla których sprawdzana jest hipoteza, że należą do tej samej powierzchni (na rysunku 13(góra), punkty te otoczone są okręgami). Na rysunkach 14 i 15 przedstawione są wartości różnic dla pikseli całych obiektów i odpowiednio dla pikseli znajdujących się w testowanych obszarach. W przypadku, gdy piksele należą do tej samej powierzchni, zmiana wartości różnic następuje płynnie, natomiast gdy punkty nie należą do tej samej powierzchni zmiana wartości różnic jest gwałtowna.


Weryfikacja hipotezy, mówiącej, że punkty należą do tej samej powierzchni polega na sprawdzeniu, czy między testowanymi punktami istnieje ścieżka, dla której wartość różnic zmienia się w sposób ciągle. Zaproponowano dwa sposoby eksploracji mapy różnic. Pierwszy z nich zakłada, że powierzchnia łącząca dwa punkty jest planarna, drugi nie korzysta z tego założenia. W obu przypadkach zmiana wartości różnic jest uważana za nieciągłą, jeśli jej wartość jest większa od pewnej wartości granicznej.

Wartość graniczna obliczana jest na podstawie rzeczywistej odległości między laserowymi punktami pomiarowymi, różnicy - ich różnic współrzędnych położenia zapisanych w wyznaczonej dla nich mapie różnic - oraz wartości progowej, która określa, jaką maksymalną odległość mogą mieć punkty należące do tej samej powierzchni.

W pierwszym przypadku, ze względu na założenie o planarności powierzchni, przegląda się mapę różnic, biorąc pod uwagę jedynie różnice leżące na prostej łączącej dwa punkty. W drugim przypadku




Rysunek 13: Oryginalne obrazy (góra), mapa różnic w skali szarości (środek), etykietowne mapy różnic (dół); dla "skręcającego pojazdu" (lewy) i dla "przesłonięcia pojazdu" (prawy).



Rysunek 14: Mapa powierzchni dla: "skręcającego pojazdu" (lewy), "przesłonięcia pojazdu" (prawy).

mapa różnic traktowana jest jako graf, przy czym piksele są węzłami. Między dwoma węzłami istnieje krawędź wtedy, jeśli różnica – ich różnic współrzędnych, między tymi pikselami jest mniejsza od wartości granicznej, wspomnianej powyżej.

Przeszukiwanie grafu w celu znalezienia ścieżki oparte jest na algorytmie A*. Modyfikacja oryginalnego algorytmu A* polega na tym, że nie poszukuje on najkrótszej ścieżki między dwoma punktami,



Rysunek 15: Mapa powierzchni testowanych obszarów dla: "skręcającego pojazdu" (lewy), "przesłonięcia pojazdu" (prawy).

lecz sprawdza, czy istnieje jakakolwiek ścieżka. Funkcja odległości oparta na metryce Czebyszewa wybrana została jako Heurystyka.

6 Podsumowanie

Celem pracy było zaproponowanie algorytmów zwiększających niezawodność systemu śledzenia obiektów ruchomych.

Dla ewaluacji zaproponowanych rozwiązań w ramach pracy stworzono symulator. Algorytmy zostały również przetestowane na rzeczywistych danych, uzyskanych przy pomocy eksperymentalnej platformy badawczej, będącej elektrycznym samochodem z zainstalowanymi na nim sensorami.

W pracy zaproponowano nowy model reprezentacji obiektów, który nie bazuje na założeniu planarności postrzeganych powierzchni, umożliwia więc reprezentację obiektów postrzeganych na powierzchniach nieplanarnych, występujących w wielu podejściach – powierzchniach rzeczywistych. Uzyskane wyniki, zarówno przy pomocy symulatora jak i danych rzeczywistych pokazują, że zaproponowany model reprezentacji obiektów jest adekwatny do celów śledzenia obiektów dynamicznych.

W celu ulepszenia estymacji stanu śledzonych obiektów wprowadzono algorytmy, biorące pod uwagę niepewność międzypromieniową oraz założenie o niezmienności rozmiaru. Eksperymenty potwierdzają, że kombinacja wspomnianych algorytmów prowadzi do lepszego oszacowania rozmiaru obiektu oraz jego położenia.

W pracy zaprezentowano również algorytm fuzji danych pochodzących z dwóch skanerów laserowych. Algorytm jest zaadaptowany do zaproponowanej metody tworzenia zorientowanego prostokąta ograniczającego. Uzyskane tą metodą estymacje wielkości, orientacji oraz prędkości dla obiektów odległych są zdecydowanie lepsze niż w przypadku, gdy dane pochodzą tylko z jednego skanera laserowego.

Praca zawiera również rozwiązania w dziedzinie asocjacji danych. Zaproponowano algorytm asocjacji oparty na metodzie najbliższego sąsiada i założeniu o niezmienności rozmiaru. Kombinacja metody NN z informacją o rozmiarze obiektu, uzyskaną przez algorytm FS, umożliwia stworzenie szybkiej i efektywnej metody asocjacji danych. Przedstawione w pracy testy pokazują, że metoda daje poprawne wyniki nawet w przypadku obiektów stykających się ze sobą.

Drugi algorytm związany z asocjacją danych jest oparty na fuzji danych pochodzących ze skanera laserowego i stereowizji. Informacje o głębi, uzyskane z obrazów stereo, wykorzystane są do klasteryzacji danych pochodzących ze skanera laserowego. Stereowizja dostarcza komplementarnych informacji o obserwowanej scenie, co umożliwia poprawną klasteryzację niemożliwą do osiągnięcia, gdy wykorzystane są tylko dane ze skanera laserowego.

Przedstawione rozwiązania otwierają wiele perspektyw badawczo-rozwojowych, posiadają formułę rozwojową z możliwością dalszej kontynuacji. Zaproponowane algorytmy oraz symulator są podstawą do kontynuowania, rozwijania i doskonalenia metod badawczych oraz przeprowadzania symulacji i uzyskiwania miarodajnych wyników.

Literatura

- [1] G. Toussaint, "Solving geometric problems with the rotating calipers," in Proc. MELECON, Athens, Greece, 1983.
- [2] A. Siadat, A. Kaske, S. Klausmann, M. Dufaut, and R. Husson, "An optimized segmentation method for a 2d laser-scanner applied to mobile robot navigation," in 3rd IFAC Symposium on Intelligent Components and Instruments for Control Applications, 1997.
- [3] K. O. Arras and R. Y. Siegwart, "Feature extraction and scene interpretation for map-based navigation and map building," in SPIE, Mobile Robotics XII, vol. 3210, Pittsburgh PA, USA, October 1997, pp. 42–53.

Publikacje:

1. Pawel Kmiotek, Yassine Ruichek, "Multisensor fusion based tracking of coalescing objects in urban environment for an autonomous vehicle navigation", IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI 2008), Korea University – Seoul – Korea, August 20-22 2008
2. Pawel Kmiotek, Yassine Ruichek, "An Oriented Bounding Box Representation Method for Tracking Dynamic Objects", Joint 4th International Conference on Soft Computing and Intelligent Systems and 9th International Symposium on advanced Intelligent Systems (SCIS & ISIS 2008), Nagoya – Japan, September 17-21 2008
3. Pawel Kmiotek, Yassine Ruichek, "Object's Oriented Bounding Box based Representation using Laser Range Finder Sensory Data", IEEE International Conference on Vehicular Electronics and Safety (ICVES 2008), Columbus Ohio – USA, September 22-24 2008
4. Pawel Kmiotek, Yassine Ruichek, "Representing and Tracking of Dynamics Objects using Oriented Bounding Box and Extended Kalman Filter", IEEE Conference on Intelligent Transportation Systems (ITSC 2008), Beijing – China, October 12-15, 2008
5. Pawel Kmiotek, Yassine Ruichek, "Two laser scanners raw sensory data fusion for objects tracking using Inter-Rays uncertainty and a Fixed Size assumption.", The 12th International Conference on Information Fusion (FUSION 2009), Seattle – USA, July 6-9, 2009
6. Pawel Kmiotek, Cyril Meurie, Frederick Zann, Yassine Ruichek, "A clustering of range sensory data by integrating stereovision information for tracking objects in urban environment.", Models and Technologies for Intelligent Transportation Systems (MTITS 2009), Rome – Italy, June 22-23, 2009
7. Pawel Kmiotek, Yassine Ruichek, "Inter-Rays uncertainty and Fixed Size assumption for objects tracking using a Laser Scanner ", The 2nd IFAC International Conference on Intelligent Control Systems and Signal Processing (ICONS 2009), Istanbul – Turkey, September 21-23, 2009
8. Pawel Kmiotek, Cyril Meurie, Yassine Ruichek, Frederick Zann, "A LRF and stereovision based data association method for objects tracking", IEEE International Conference on Systems, Man, and Cybernetics (SMC 2009), San Antonio – USA, October 11-14, 2009
9. Pawel Kmiotek, Yassine Ruichek, "A Fixed Size Assumption Based Data Association Method for Coalescing Objects Tracking using a Laser Scanner Sensor", The 2009 IEEE International Conference On Vehicular Electronics and Safety (ICVES 2009), Pune – India November 10-12, 2009