

WIELOSENSORYCZNA BUDOWA MODELU OTOCZENIA W SIECI PERCEPCYJNEJ

Streszczenie : W pracy przedstawiono koncepcję sieci percepcyjnej zastosowanej do wielosensorycznej budowy modelu otoczenia robota mobilnego. Proponowane rozwiązanie charakteryzuje się zastosowaniem różnych map otoczenia oraz modeli niepewności dostosowanych do użytych sensorów i zadań robota. Przedstawiono wyniki eksperymentów z użyciem optycznych i ultradźwiękowych sensorów odległości oraz danych apriorycznych.

MULTI-SENSOR ENVIRONMENT MODELLING IN A PERCEPTION NETWORK

Abstract : The concept of Perception Network with application to the multi-sensor perception for a mobile robot is discussed. The proposed system uses different map classes and uncertainty models to handle different sensor characteristics and specific robot-tasks. The results of experimental map building by using data from range sensors combined with the predefined world-model are presented.


1. WSTĘP

Skuteczna percepcja otoczenia, zapewniająca zgodność modelu wykorzystywanego do planowania zadań i sterowania z faktycznym stanem sceny umożliwia autonomiczne działanie robotów mobilnych. Systemy wielosensoryczne pozwalają budować model otoczenia charakteryzujący się większym bogactwem postrzeganych cech (przy użyciu sensorów o komplementarnych właściwościach, np. dalmierzy laserowych i ultradźwiękowych) oraz zmniejszoną niepewnością wykrytych cech (przy zastosowaniu sensorów o różnych charakterystykach niepewności — jak sonary i systemy wizyjne) [5]. Dopelnieniem modelu otoczenia zbudowanego w oparciu o aktualne dane z wielu źródeł mogą być informacje o środowisku dane *a priori*. Ich wykorzystanie pozwala badać zgodność faktów zgromadzonych w modelu z układem aktualnych ograniczeń zawartych w bazie wiedzy apriorycznej [11]. Realizacja systemu percepcji i budowy modelu otoczenia korzystającego z wielu, istotnie różnych źródeł informacji wymaga sprowadzenia obserwacji sensorycznych do wspólnej reprezentacji oraz uzgodnienia jednolitego modelu niepewności. Zastosowanie jednego z typowych podejść do łączenia danych [2, 7] prowadzi do rozwiązania kompromisowego — reprezentacja modelu i/lub sposób opisu niepewności nie są odpowiednie dla wszystkich komponentów systemu.

W niniejszej pracy zaproponowano nowe podejście do procesu wymiany i łączenia informacji sensorycznej z wielu źródeł. Polega ono na wprowadzeniu sieci percepcyjnej (PN) [4], unifikującej powiązania między sensorami i modelami otoczenia. Przedstawiono strukturę PN, zastosowane metody łączenia danych sensorycznych i konwersji modeli otoczenia (wraz z modelami niepewności) oraz podsystem wnioskowania opartego na regułach. Zaprezentowano wyniki uzyskane podczas eksperymentów.

2. KONCEPCJA

Z formalnego punktu widzenia sieć percepcyjna jest skierowanym grafem, którego wierzchołki reprezentują elementy przechowujące, zaś krawędzie elementy przetwarzające informacje. Sieć ta reprezentuje przepływ informacji od źródeł (sensorów) do modeli otoczenia (rys. 1B). PN umożliwia łączenie danych pomiarowych różnego typu oraz wyekstrahowanych cech w modele otoczenia robota wykorzystywane następnie do planowania zadań i kontroli operacji autonomicznych. W przypadku robotów mobilnych modele te służą do planowania ścieżki i pozycjonowania.



Rys. 1: Sensory logiczne w strukturze sieci percepcyjnej


Wymiana danych między cząstkowymi modelami otoczenia (wierzchołkami sieci) dokonywana jest w celu zmniejszenia niepewności gromadzonej informacji, na zasadzie porównywania i łączenia modeli budowanych za pomocą poszczególnych sensorów. Dzięki temu może powstać model otoczenia, bardziej aktualny i charakteryzujący się mniejszą niepewnością niż modele budowane za pomocą poszczególnych sensorów z osobna. Jednocześnie wprowadza się mechanizmy zapewniające spójność z aprioryczną wiedzą o otoczeniu (pochodzącą z systemu typu CAD) [11]. W porównaniu z koncepcją sieci percepcyjnej przedstawioną w [4], rozszerzono rozwiązanie poprzez wprowadzenie map otoczenia robota do struktury sieci, jako jej podstawowych wierzchołków. Taka modyfikacja pozwala na zastosowanie PN w charakterze wieloaspektowego, rozproszonego, przyrostowego modelu środowiska robota. Istotne jest też jednocześnie stosowanie w sieci zróżnicowanych modeli niepewności informacji (modeli wariancyjno-kowariancyjnych [2], probabilistycznych [3, 8]). By zunifikować źródła informacji wykorzystano koncepcję sensora logicznego (rys. 1A), co pozwala niezależnie interpretować istotnie odmienne cechy środowiska postrzegane przez dany sensor fizyczny [1]. Sensory logiczne dokonują konwersji informacji pomiędzy poszczególnymi jej źródłami, sensorami fizycznymi i reprezentacjami otoczenia (rys. 1B). Konwersja ta polega na ekstrakcji cech wyższego poziomu z reprezentacji niższego poziomu (np. prymitywów wektorowych z danych skanera optycznego lub mapy rastrowej) oraz wzajemnym dopasowywaniu postaci danych na tym samym poziomie abstrakcji (dane ze skanera i sonarów wykorzystywane do aktualizacji tej samej mapy rastrowej).

3. REALIZACJA

Realizację koncepcji sieci percepcyjnej dla robota mobilnego stanowi zestaw procedur przetwarzających dane z jego sensorów. Procedury te są powiązane przez wzajemną wymianę danych oraz reguły zapewniające spójność otrzymywanych modeli otoczenia z

modelem apriorycznym. Wykorzystane procedury łączenia i konwersji danych stanowią krawędzie sieci percepcyjnej, zaś sensory i budowane mapy jej wierzchołki.

W obecnej wersji systemu wykorzystywane są dane z sensorów odległości (optycznych i ultradźwiękowych) oraz wiedza aprioryczna o otoczeniu robota [11]. Jako modele otoczenia w sieci percepcyjnej zastosowano mapy rastrowe i wektorowe. Oba te sposoby reprezentacji otoczenia mają odmienne właściwości, lecz są w pewnym stopniu komplementarne. Modele rastrowe cechuje prosty sposób reprezentacji niepewności poprzez rasteryzację przestrzeni oraz prawdopodobieństwo zajęcia komórki. Jednolita reprezentacja niepewności pozwala łączyć dane z różnych rodzajów sensorów [3]. Modele wektorowe (parametryczne) cechuje możliwość efektywnego opisu dużych obszarów roboczych, śledzenia zmian stanu otoczenia dynamicznego, oraz zgodność reprezentacji z apriorycznymi modelami CAD [10, 11, 12]. Budowa wiarygodnego modelu wektorowego na podstawie niewielkiej ilości niepewnych danych jest jednak trudna, często nie ma możliwości identyfikacji i usunięcia z mapy elementów powstałych na skutek błędnej interpretacji niekompletnych danych [10].



Rys. 2: Wykorzystanie odmiennych modeli niepewności


W sieci percepcyjnej zastosowano oba typy modeli na równych prawach, nie wprowadzając żadnej sztywnej hierarchii map (np. architektury warstwowej [3]). Sposób aktualizacji map wektorowych i rastrowych oraz ich wykorzystania w nawigacji robota wynika z własności samych modeli oraz charakterystyk sensorów [6]. Mapy rastrowe aktualizowane są częściej, gdyż mogą efektywnie wykorzystać dane z sonarów, dokonujących pomiarów w czasie jazdy robota. Dane ze skanera optycznego są integrowane w mapie rastrowej z mniejszą częstotliwością, (znacznie "wolniejszy" sensor), jako bardziej wiarygodne pozwalają jednak usunąć wiele nieprawidłowych odczytów sonarów już na wczesnym etapie przetwarzania.

W literaturze znane są różne metody budowy map rastrowych wykorzystujące np. formalizm Bayes'owski [3] lub teorię Dempstera-Shafera [14]. W prezentowanym systemie zaimplementowano (głównie w celach porównawczych) obie metody aktualizacji map rastrowych. Metoda Bayes'owska jest implementacją algorytmu zaproponowanego przez Elfesa. Modyfikacje polegają na zmianie funkcji opisujących kształt wiązki pomiarowej sensora. Dla sonarów przyjęto równomierny rozkład prawdopodobieństwa zajęcia komórek w funkcji kąta rozwarcia wiązki, oraz rozkład Gaussowski w funkcji mierzonej odległości. Dla skanera optycznego wiązka ma kąt rozwarcia równy 2° , a zależność prawdopodobieństwa zajęcia od zmierzonej odległości $P_o = f(r, \sigma_r)$ ma rozkład Gaussowski o wariancji σ_r . Zależności te zostały wyznaczone na podstawie wcześniejszych badań właściwości skanera optycznego [5]. W przeciwieństwie do znanych rozwiązań [3] funkcja prawdopodobieństwa dla skanera nie jest stała, lecz obliczana dla każdego nowego pomiaru.

Pozwala to uwzględnić statystyczną korekcję zmierzonych odległości [12] i usunąć część błędnych pomiarów. Metodę budowy mapy opartą na teorii Dempstera-Shafera [8, 14] zaimplementowano w podobny sposób, wykorzystując te same metody wyznaczania prawdopodobieństwa zajęcia komórki. Komórki mapy rastrowej opisane są zbiorem hipotez (1) wraz z przypisanymi im wartościami masy prawdopodobieństwa m :

$$\begin{aligned} m(\text{cell_occupied}) : P_o &= f(r, \sigma_r), \\ m(\text{cell_empty}) : P_e &= k * (1 - P_o), \\ m(\text{cell_unknown}) : P_u &= 1 - P_o - P_e, \end{aligned} \quad (1)$$

gdzie k jest współczynnikiem określającym stosunek prawdopodobieństwa zajęcia komórki do prawdopodobieństwa bycia wolną na podstawie pomiaru. Mapa rastrowa budowana jest z wykorzystaniem wzoru Dempstera na łączenie informacji ze źródeł o odmiennych rozkładach prawdopodobieństw [8]. Dla każdej z hipotez (1) wyznaczyć można funkcję "wsparcia" (*support* — Spt) i "wyobraźności" (*plausibility* — Pls). O prawdziwości danej hipotezy można wnioskować na podstawie stosunku wartości obu funkcji. Na przykład, jeżeli dla hipotezy *cell_occupied* zarówno Spt jak i Pls będą mieć dużą wartość, można uznać prawdziwość tej hipotezy dla danej komórki (obszaru mapy). Jeżeli natomiast dla tej samej hipotezy Spt będzie mieć małą wartość a Pls dużą, należy uznać że ilość informacji zgromadzonych o danym obszarze jest zbyt mała. Istotna jest też możliwość wyznaczenia miary niezgodności między dwoma źródłami informacji o odmiennym rozkładzie prawdopodobieństw (np. różnymi sensorami) [8].



Rys. 3: Konwersja mapy rastrowej na postać wektorową przez sensor logiczny

W sieci percepcyjnej mapa wektorowa została zaimplementowana jako pojedyncza struktura danych o charakterze globalnym integrująca, z wykorzystaniem filtracji Kalmana, danej w postaci prymitywów wektorowych [11, 12]. Prymitywy dostarczane są przez sensory logiczne, będące ekstraktorami cech działającymi na danych z sensora fizycznego (skaner), strukturze danych (lokalna mapa rastrowa) lub bazy wiedzy apriorycznej [11]. Sposób pozyskiwania prymitywów wektorowych z danych skanera optycznego opisano w [10] oraz [12]. Ponieważ robot działa w pomieszczeniach zamkniętych, jego otoczenie składa się w przeważającej mierze z fragmentów prostoliniowych. Do poszukiwania takich

odcinków w mapach rastrowych wykorzystano transformatę Hough'a. Jest ona dobrze znana jako metoda wykrywania cech (w ogólności krzywych o określonych kształtach) na obrazach z kamer wizyjnych [9]. W przestrzeni parametrów Hough'a ρ_H, ϕ_H znajdujące się maksima odpowiadające prostoliniowym prymitywom w mapie rastrowej, opisanym równaniem :

$$x \cos(\phi) + y \sin(\phi) - \rho = 0. \quad (2)$$

Jednak mapa rastrowa w porównaniu z obrazem z kamery charakteryzuje się bardzo "grubymi" konturami przeszkód, utrudniającymi jednoznaczne wpasowanie prymitywów wektorowych. W związku z tym zastosowano algorytm *szkieletyzacji* mapy rastrowej jako pierwszy etap jej przetwarzania. Transformata Hough'a dokonywana jest na obrazie binarnym (szkielecie), a jedynie w przypadku wystąpienia niejednoznaczności algorytm odwołuje się do obrazu "szarego" tzn. właściwej mapy rastrowej. Kolejnym problemem jest określenie niepewności znalezionej odcinka w formie zgodnej z obowiązującą dla mapy wektorowej [12]. Transformata Hough'a nie pozwala bezpośrednio znaleźć miary niepewności, a także sama wprowadza dodatkową niepewność ze względu na dyskretyzację przestrzeni parametrów ρ_H, ϕ_H [9]. Z tego względu zastosowano wyznaczanie parametrów linii prostej $L = [\rho, \phi]^T$, oraz jej macierzy kowariancji C_L na podstawie metody najmniejszych kwadratów, identycznie jak dla przetwarzania danych ze skanera [10, 11]. Jako współrzędne punktów składowych odcinka wykorzystuje się środki komórek mapy rastrowej które zaliczone zostały do danej prostej przez transformatę Hough'a. Niepewność położenia takiego punktu (macierz kowariancji C_P) zależy od wielkości komórek mapy (im większe Δ_{raster} tym większa niepewność) oraz wartości współczynnika "zajętości" danej komórki $P_0^{(x,y)}$:


$$C_P = \begin{bmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{bmatrix}, \quad \sigma_x = \sigma_y = \Delta_{raster} * \frac{1}{P_0^{(x,y)}} \quad (3)$$

Prymitywy wektorowe otrzymane przez zastosowanie opisanej powyżej procedury są łączone w mapie wektorowej identycznie jak prymitywy otrzymane bezpośrednio z danych skanera optycznego. Zaletą prymitywów odtworzonych z lokalnych map rastrowych jest mniejsza ilość elementów wynikających z błędnych danych sensorycznych, na skutek zgromadzenia większej ilości informacji w mapie rastrowej niż w pojedynczym skanie. Poprzez konwersję map rastrowych możliwe jest też uwzględnienie w mapie wektorowej danych z sonarów, pomimo zupełnie różnych w stosunku do sensora optycznego charakterystyk niepewności oraz innej rozdzielczości kątowej.

Obok wymiany danych przez sensory logiczne, elementem wiążącym modele otoczenia w sieci percepcyjnej jest podsystem wnioskowania oparty na regułach [11]. Przetwarzanie oparte o reguły ma zastosowanie do modeli opisanych parametrycznie — w istniejącej implementacji do globalnej mapy wektorowej. Mechanizm dopasowywania i łączenia prymitywów w mapę wektorową oparty na filtracji Kalmana uzupełniono systemem prostych *reguł postępowania* względem umieszczanych w mapie prymitywów, w zależności od ich związku z apriorycznym modelem otoczenia uzyskanym z opisu CAD [11, 12]. Obecnie podsystem ten zrealizowano jako warunki if - then - else zakodowane w proceduralnym języku programowania, jako część procedur budowy mapy wektorowej. Przykładowe reguły zaprezentowano poniżej :

1. jeżeli nowy element (prymityw) L_{new} zostaje dopasowany do apriorycznego elementu mapy o atrybucie *solid.object* (np. ściana pomieszczenia) to jest on kasowany — nie zmienia parametrów istniejącego obiektu,

2. jeżeli L_{new} zostaje dopasowany do elementu mapy który nie występuje w bazie wiedzy apriorycznej (np. tymczasowa ściana zestawiona z kartonowych pudeł) to zmienia parametry istniejącego obiektu zgodnie ze wzorami opisującymi łączenie dowolnych prymitywów [12],
3. jeżeli L_{new} zostaje dopasowany do elementu mapy który w bazie wiedzy ma atrybut *not_deformable* (np. stół, szafa itp.) to zmienia parametry istniejącego obiektu do którego został bezpośrednio dopasowany (np. jednej krawędzi stołu) zgodnie z odpowiednimi wzorami, lecz parametry pozostałych krawędzi wchodzących w skład obiektu (np. pozostałe boki stołu) są dopasowywane tak by zachować pierwotny kształt obiektu.



Rys. 4: Wykorzystanie informacji apriorycznej


System regułowy pozwala usunąć z mapy wektorowej pewne wpisy które mogą być wynikiem błędnego przetwarzania na wcześniejszych etapach (w sensorach logicznych) oraz zapewnia spójność mapy globalnej z dostępnymi *a priori* danymi geometrycznymi i wiedzą dziedzinową. W trakcie dalszych prac planowane jest zwiększenie liczby reguł opisujących dostępną wiedzę oraz ich implementacja przy pomocy bardziej odpowiedniego narzędzia (np. języka *Prolog*) [13].

4. WYNIKI

Przeprowadzono doświadczalną weryfikację elementów sieci percepcyjnej na stanowisku badawczym składającym się z robota mobilnego klasy *Labmate* z dalmierzem/skanerem optycznym [5] i dalmierzami ultradźwiękowymi. Wykorzystano też dane ze skanera laserowego *Sick LMS 200* udostępnionego w ramach współpracy¹ przez *Universidad Politécnica de Cartagena* (Hiszpania). Wykorzystywane w eksperymentach pomieszczenie laboratorium jest niewielkie, a ze względu na dużą ilość małych obiektów (komputery, stoliki, krzesła — rys. 3A) budowa jego modelu jest trudna. W takim środowisku sensory generują wiele błędnych i sprzecznych odczytów, na rysunku 3B przedstawiono je jaśniejszym kolorem, kolor ciemniejszy to odczyty zakwalifikowane jako prawidłowe.

Na rysunku 2 przedstawiono mapy rastrowe laboratorium uzyskane przy zastosowaniu dwóch różnych modeli niepewności, Bayesa (A) i Dempstera-Shafera (B1 *support* i B2 *plausibility*). Model Dempstera-Shafera pozwala lepiej zidentyfikować miejsca w których

¹Finansowanej przez KBN w ramach wymiany osobowej WO-99/2




Rys. 5: Przykładowe mapy będące efektem łączenia i konwersji danych

dane ze skanera były niejednoznaczne (lewa-górna część mapy). Na rysunku 3 przedstawiono sekwencję konwersji mapy rastrowej pomieszczenia laboratorium (rys. 3C) na mapę wektorową. Rysunek 3D przedstawia mapę po szkieletowaniu, 3E mapę wektorową uzyskaną przez transformację Hough'a, a 3F tę samą mapę po usunięciu mało wiarygodnych prymitywów.

Jakość budowanej mapy globalnej można poprawić korzystając z danych dostępnych *a priori*. Na rysunku 4 przedstawiono uproszczoną aprioryczną mapę pomieszczenia laboratorium (A), mapę wektorową utworzoną na podstawie bezpośrednich pomiarów skanerem optycznym (B) oraz mapę powstałą w wyniku fuzji informacji apriorycznej i aktualnych danych sensorycznych (C).

Zdolność sieci percepcyjnej do integracji danych z odmiennych sensorów sprawdzono w praktyce ustawiając z kartonowych pudeł testowe środowisko na korytarzu. Na rysunku 5 przedstawiono mapę rastrową (obszary zajęte) otoczenia robota utworzoną na podstawie pomiarów skanerem optycznym (A) oraz uzyskaną na jej podstawie globalną mapę wektorową (B), wykorzystywaną przez system nawigacji robota mobilnego. Rysunek 5C przedstawia mapę rastrową uzyskaną w wyniku fuzji opisów otoczenia ze skanera i dalmierzy ultradźwiękowych, a rysunek 5D mapę wektorową powstałą przez konwersję tej mapy rastrowej.



Rys. 6: Dane ze skanera laserowego (B) i uzyskana mapa wektorowa (C)

Przeprowadzono również eksperyment z wykorzystaniem jako źródła danych dla PN skanera laserowego *LMS 200* (rys. 6A). Zmodyfikowano oprogramowanie sensora logicznego korzystającego ze skanera optycznego KARIi przystosowując je do protokołu obsługi nowego sensora. Pozostałe elementy PN nie wymagały żadnych zmian. Rysunek 6 prezentuje uzyskane wyniki.

5. WNIOSKI

W artykule przedstawiono podstawy koncepcji sieci percepcyjnej, proponowanej jako nowe podejście do zbierania i przetwarzania informacji z wielu sensorów na potrzeby systemu nawigacji robota mobilnego. Przedstawiono sposób praktycznej realizacji prostej sieci wykorzystującej dane z sensorów odległości oraz mapy rastrowe i wektorowe jako modele otoczenia. Zaprezentowano wyniki eksperymentów potwierdzających zdolność proponowanego systemu do łączenia danych z różnych źródeł, integracji wiedzy apriorycznej, oraz możliwość łatwego dołączania nowych sensorów.

ACKNOWLEDGEMENTS

Many thanks are due to Dr. Jo e-Luis Mu oz Lozano of the Universidad Polit cnica de Cartagena, Spain, for his contribution to the experiments with the Sick laser scanner.

LITERATURA

- [1] Henderson T., Shilcrat E. *Logical Sensor Systems*. Journal of Robotic Systems, 2(1), 1984. 169-193
- [2] Durrant-Whyte H.F. *Sensor Models and Multisensor Integration*. In: Autonomous Robot Vehicles, (I. Cox and G. Wilfong, eds.). Springer-Verlag, 1990. 73-89
- [3] Elfes A. *Incorporating Spatial Representations at Multiple Levels of Abstraction in a Replicated Multilayered Architecture for Robot Control*. In: Intelligent Robots: Sensing, Modeling and Planning, (R. Bolles et al., eds.). World Scientific, 1997. 249-266.
- [4] Lee S., Ro S., Schenker P. *Perception-Net Based Geometric Data Fusion for State Estimation and System Self-Calibration*. Proc. Conf. Intelligent Robots and Systems, Grenoble, 1997. 1375a-1375g
- [5] Majchrzak J., Skrzypczyński P., Wiczyński G. *Aktywne sensory robotów mobilnych*, WMR'97, Zakopane, 1997. 15-22
- [6] Kasiński A., Skrzypczyński P. *Cooperative Perception and World-Model Maintenance in Mobile Navigation Tasks*. In: Distributed Autonomous Robotic Systems 3 (T. Lueth et al., eds.), Springer Verlag, 1998. 173-182
- [7] Luo R. C., Kay M. G. *Multisensor Integration and Fusion in Intelligent Systems*. IEEE Trans. on Systems, Man, and Cybernetics, 19(5), 1989. 61-70
- [8] Murphy R. *Dempster-Shafer Theory for Sensor Fusion in Autonomous Mobile Robots*. IEEE Trans. on Robotics and Automation, 14(2), 1998.
- [9] Shirai Y. *Tree-Dimensional Computer Vision*. Springer-Verlag, Berlin, 1987.
- [10] Skrzypczyński P. *2D and 3D World Modelling Using Optical Scanner Data*. In: Intelligent Robots: Sensing, Modeling and Planning, (R. Bolles et al., eds.). World Scientific, 1997. 211-228
- [11] Skrzypczyński P., Drapikowski P. *Environment Modelling for a Multi-Agent Mobile System*. European Workshop on Advanced Mobile Robots EUROBOT'99, Zurich, 1999. 41-48
- [12] Skrzypczyński P., Drapikowski P., Jedwabny T., *Model-Based Navigation of Industrial Mobile Robots*. AUTOMATION'99, Warszawa, 1999.
- [13] Sriram R. D. *Intelligent Systems for Engineering*. Springer-Verlag, 1997.
- [14] Tirumalai A., Brian B., Jain R. *Evidential Reasoning for Building Environment Maps*. IEEE Trans. on Systems, Man, and Cybernetics, 25(1), 1995. 10-20