

Zdzisław KOWALCZUK, Mariusz DOMŻALSKI

POLITECHNIKA GDAŃSKA, WYDZIAŁ ELEKTRONIKI, TELEKOMUNIKACJI I INFORMATYKI

Rozproszony system wyznaczania trajektorii poruszających się obiektów

Prof. dr hab. inż. Zdzisław KOWALCZUK

Profesor zwyczajny i kierownik Katedry Systemów Decyzyjnych, Wydział Elektroniki Telekomunikacji i Informatyki Politechniki Gdańskiej. Urodzony w Gdańsku 1953, mgr inż. 1978, dr 1986, dr hab. 1993, profesor nauk technicznych 2003. Zakres badań naukowych: teoria i projektowanie komputerowych systemów sterowania i diagnostyki oraz adaptacja, modelowanie i identyfikacja, przetwarzanie sygnałów i sztuczna inteligencja. Laureat Nagrody Fundacji na Rzecz Nauki Polskiej (1999) w dziedzinie nauk techn.

e-mail: kova@eti.pg.gda.pl



Mgr inż. Mariusz DOMŻALSKI

Absolwent Wydziału Elektroniki, Telekomunikacji i Informatyki Politechniki Gdańskiej. Obecnie pracuje jako asystent w Katedrze Systemów Decyzyjnych. Dziedzina jego zainteresowań jest estymacja stanu obiektów dynamicznych, a w szczególności metody wyznaczania trajektorii poruszających się obiektów korzystając z danych z wielu źródeł.

e-mail: mardo@eti.pg.gda.pl



Streszczenie

W pracy rozważa się problem śledzenia trajektorii poruszających się obiektów przy użyciu rozproszonego systemu śledzenia. W systemie takim trajektoria poruszającego się obiektu jest wyznaczana przez grupę lokalnych estymatorów. Każdy z tych estymatorów korzysta z filtru Kalmana i danych z pojedynczego źródła w celu określenia trajektorii obiektu. Następnie wyznaczone trajektorie przesyłane są do systemu centralnego, gdzie następuje ich fuzja, czyli proces określania na podstawie trajektorii lokalnych jednej, potencjalnie najdokładniejszej trajektorii centralnej.

Słowa kluczowe: wyznaczanie trajektorii, estymacja stanu, filtracja Kalmana, wiele źródeł danych, rozproszone systemy śledzenia.

Distributed tracking system for trajectories estimation of moving objects

Abstract

This paper considers the problem of tracking moving objects using a distributed multi-sensor system. In such a system a trajectory of a moving object is estimated by a group of local estimators. Each local estimator utilizes a Kalman filter and data from a single source to determine a local trajectory of the object. Computed trajectories are sent to a central processor, which performs data fusion, i.e. combines trajectories from multiple local estimators so as to obtain an optimal trajectory, representing possibly best estimates of the kinematics states of the objects.

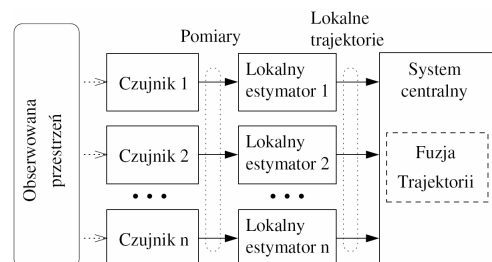
Keywords: tracking systems, state estimation, Kalman filters, multiple data sources, distributed tracking systems.

1. Wstęp

Estymata (ocena) trajektorii to ciąg estymat stanu, reprezentujących kinematyczne cechy obserwowanego obiektu, np. położenie, prędkość czy przyspieszenie. Zwykle systemy wyznaczania trajektorii oparte są na pojedynczym filtrze Kalmana [1, 2, 3, 4], jednak w wielu przypadkach użycie tylko jednego źródła danych jest niewystarczające dla zapewnienia wymaganej dokładności i niezawodności. W takiej sytuacji konieczne staje się skorzystanie z informacji z wielu źródeł oraz z algorytmu, który taką informację mógłby przetworzyć.

Wyznaczanie trajektorii poruszających się obiektów zwykle realizuje się w jednej z dwóch struktur: centralnej bądź rozproszonej. W systemie z przetwarzaniem centralnym [2], nieprzetworzone pomiary uzyskane z czujników przesyłane są bezpośrednio do wspólnego algorytmu wyznaczania trajektorii. W takiej architekturze algorytm estymacji analizuje nieprzetworzoną informację o obserwowanym obiekcie. Niestety implementacja takiego systemu w praktyce może trafić na liczne ograniczenia, związane na przykład z przepustowością kanałów komunikacyjnych. Co więcej, z powodu implementacyjnych różnic pomiędzy czujnikami, skorzystanie z istniejącej infrastruktury przy konstrukcji nowego systemu wyznaczania trajektorii może być niemożliwe.

W systemie z przetwarzaniem rozproszonym [2, 5, 6] każdy czujnik skojarzony jest z lokalnym estymatorem stanu. Estymatorem takim może być np. filtr Kalmana lub filtr PDA [2]. Czujnik wraz z estymatorem tworzy ośrodek lokalny, w którym estymowane są lokalne trajektorie obiektu na podstawie danych z pojedynczego źródła. Tak wyznaczone we wszystkich ośrodkach lokalnych trajektorie przesyłane są do algorytmu nadrzędnego, który analizuje tę przetworzoną informację. Zadaniem algorytmu nadrzędnego jest przede wszystkim optymalne połączenie trajektorii lokalnych w jedną trajektorię globalną, która możliwie najdokładniej opisuje ruch obserwowanego obiektu. Do podstawowych zalet rozwiązania rozproszonego należy dostępność lokalnych estymat stanu oraz możliwość korzystania z różnych kinematycznych modeli obiektu w poszczególnych ośrodkach lokalnych. Ponadto, dane przesyłane z ośrodków lokalnych są tego samego typu (estymaty stanu). Upraszcza to konstruowanie nowego rozproszonego systemu wyznaczania trajektorii na bazie istniejącej infrastruktury. Wadą systemów rozproszonych jest większa złożoność nadrzędnego algorytmu wyznaczania trajektorii. Na rys. 1 przedstawiono schemat rozproszonego systemu wyznaczania trajektorii w sytuacji, gdy obiekt poruszający się w przestrzeni obserwowany jest przez n niezależnych czujników.



Rys. 1. Rozproszony system wyznaczania trajektorii
Fig. 1. Distributed tracking system

Praca zorganizowana jest w sposób następujący. W rozdziale 2 przedstawiono przykładowy liniowy model obiektu używany w systemach wyznaczania trajektorii. Rozdział 3 stanowi krótkie przypomnienie zasad filtru Kalmana. W rozdziale 4 przedstawiono rozproszony algorytm wyznaczania trajektorii. Rozdział 5 zawiera wyniki badań symulacyjnych oraz wnioski.

2. Modele kinematyczne obiektu

Przykładowy model dynamiki obiektu oraz przykładowe równanie obserwacji opisujące zasadę działania czujnika przedstawiono poniżej.

Rozważmy ruch obiektu w przestrzeni dwuwymiarowej opisany poniższym dyskretnym równaniem modelującym dynamikę

$$x(k) = Fx(k-1) + Gu(k-1). \quad (1)$$

Stan $x(k)$ reprezentowany jest wektorem kolumnowym:

$$x(k) = [p_x(k) \ p_y(k) \ v_x(k) \ v_y(k)]^T, \quad (2)$$

gdzie $p_x(k)$, $p_y(k)$ to współrzędne położenia w przestrzeni Kartezjańskiej, natomiast $v_x(k)$, $v_y(k)$ to składowe prędkości obiektu. Oznaczając czas próbkowania przez T , macierz przejścia stanu w modelu opisującym ruch wyrażamy następująco:

$$F = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (3)$$

Biały szum gaussowski o zerowej wartości średniej, oznaczany jako:

$$u(k) = [u_x(k) \ u_y(k)]^T, \quad (4)$$

opisuje nieprzewidywalne manewry wykonywane przez obiekt oraz wpływ czynników zewnętrznych, takich jak np. wiatr w przypadku obiektów latających. Zakłada się, że znana jest macierz kowariancji U procesu $u(k)$. W przypadku, gdy proces $u(k)$ ma charakter nieznanego przyspieszenia, macierz wejściowa G ma następującą postać:

$$G = \begin{bmatrix} \frac{1}{2}T^2 & 0 & T & 0 \\ 0 & \frac{1}{2}T^2 & 0 & T \end{bmatrix}^T. \quad (5)$$

Macierz kowariancji procesu $Gu(k)$ wynosi:

$$Q = GUG^T = \begin{bmatrix} \frac{1}{4}T^4U & \frac{1}{2}T^3U \\ \frac{1}{2}T^3U & T^2U \end{bmatrix}. \quad (6)$$

W analogiczny sposób, bazując na równaniach kinematyki, można opisać ruch obiektu w trzech wymiarach. Wektor stanu w modelu ruchu można również rozszerzyć o współrzędną opisującą przyspieszenie obserwowanego obiektu.

W powyższym modelu nie rozważamy deterministycznego wejścia, gdyż jego obecność nie wpływa na istotę prezentowanego algorytmu estymacji trajektorii.

W przypadku, gdy mierzone jest tylko położenie obiektu, równanie obserwacji zdefiniowane jest następująco:

$$z(k) = Hx(k) + w(k), \quad (7)$$

gdzie macierz obserwacji

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}, \quad (8)$$

zaś

$$w(k) = [w_x(k) \ w_y(k)]^T \quad (9)$$

jest białym szumem gaussowskim o zerowej wartości średniej, który modeluje niepewność pomiaru. Zwykle przyjmuje się, że

związana z konkretnym czujnikiem macierz kowariancji R procesu w jest znana.

3. Filtr Kalmana

Przy wyznaczaniu trajektorii poruszającego się obiektu estymatory lokalne korzystają z filtru Kalmana. Kompletny opis tego filtru znaleźć można w [1,3].

Korzystając z modelu obiektu wprowadzonego w rozdziale poprzednim oraz z wyników estymacji z poprzedniej chwili $k-1$, przewidywany stan obiektu wyznaczany jest następująco:

$$\hat{x}(k | k-1) = F\hat{x}(k-1 | k-1), \quad (10)$$

wraz z odpowiadającą mu macierzą kowariancji (błędu estymacji przewidywanego stanu)

$$P(k | k-1) = FP(k-1 | k-1)F^T + Q, \quad (11)$$

gdzie macierz Q opisana jest wzorem (6).

Przewidywany pomiar wyznaczany jest na podstawie równania obserwacji (7):

$$z(k | k-1) = H\hat{x}(k | k-1). \quad (12)$$

z kowariancją przewidywanego pomiaru w postaci:

$$\hat{z}(k | k-1) = H\hat{x}(k | k-1), \quad (13)$$

gdzie R jest macierzą kowariancji procesu (9).

Innowacja wyznaczana jest w każdym cyklu pracy filtru jako różnica rzeczywistego pomiaru $z(k)$ uzyskanego z czujnika oraz pomiaru przewidywanego (12):

$$v(k) = z(k) - \hat{z}(k | k-1). \quad (14)$$

Wzmocnienie filtru Kalmana obliczane jest następująco:

$$W(k) = P(k | k-1)H^T S(k)^{-1}. \quad (15)$$

Na koniec każdego cyklu pracy filtru aktualizowany jest stan obiektu:

$$x(k | k) = x(k | k-1) + W(k)v(k), \quad (16)$$

oraz odpowiadająca mu macierz kowariancji (zgodnie z regułą Joseph'a) jako:

$$P(k | k) = (I - W(k)H)P(k | k-1)(I - W(k)H)^T + W(k)RW(k)^T. \quad (17)$$

4. Rozproszony algorytm estymacji trajektorii

Estymaty trajektorii obiektu $\hat{x}^i(k | k)$ niezależnie wyznaczane w ośrodkach lokalnych dla każdej chwili k przesyłane są do centralnego ośrodka nadrzędnego. Ośrodek centralny korzysta z tych estymat i wyznacza jedną, potencjalnie najdokładniejszą estymatę centralną $\hat{x}^c(k | k)$. Rozproszony algorytm wyznaczania trajektorii oparty będzie na Najlepszym Liniowym Estymatorze Nieobciążonym nie korzystającym z informacji a priori [7, 8], przedstawionym poniżej.

Estymata stanu otrzymana z i -tego ośrodka lokalnego (18) może być interpretowana jako obserwacja prawdziwego stanu obiektu w chwili k zakłócona pewnym 'błędem estymacji', zatem

$$\hat{x}^i(k|k) = \hat{x}^i(k|k) - x(k) + x(k), \quad (18)$$

oznaczając błąd estymacji i -tego ośrodka jako $\tilde{x}^i(k|k) = x(k) - \hat{x}^i(k|k)$:

$$\tilde{x}^i(k|k) = x(k) - \hat{x}^i(k|k). \quad (19)$$

Odpowiednio zagregowany model obserwacji dla wszystkich n ośrodków lokalnych ma postać:

$$y(k) = \Gamma x(k) + \gamma(k), \quad (20)$$

przyjawszy:

$$y(k) = [(\tilde{x}^1(k|k))^T \dots (\tilde{x}^i(k|k))^T \dots (\tilde{x}^n(k|k))^T]^T, \quad (21)$$

$$\Gamma = [I \dots I \dots I]^T, \quad (22)$$

$$\gamma(k) = [(-\tilde{x}^1(k|k))^T \dots (-\tilde{x}^i(k|k))^T \dots (-\tilde{x}^n(k|k))^T]^T, \quad (23)$$

gdzie I jest macierzą jednostkową o odpowiednim rozmiarze.

Kowariancja błędów $\gamma(k)$ zdefiniowana jest jako:

$$\text{cov}\{\gamma(k)\} = E\{\gamma(k)\gamma^T(k)\} = [E\{\tilde{x}^i(k|k)(\tilde{x}^j(k|k))^T\}] \quad (24)$$

$$i, j = 1, \dots, n.$$

Równania algorytmu fuzji estymat stanu, wyznaczające centralną estymatę $\hat{x}^c(k|k)$ przedstawione są poniżej:

$$\hat{x}^c(k|k) = V(k)y(k), \quad (25)$$

$$P^c(k|k) = V(k)\text{cov}\{\gamma(k)\}V^T(k), \quad (26)$$

$$V(k) = \Gamma^+[I - \text{cov}\{\gamma(k)\}(B\text{cov}\{\gamma(k)\}B)^*]^{-1}, \quad (27)$$

gdzie $B = I - \Gamma^+$ oraz operator $(\cdot)^+$ wyznacza lewostronną macierz pseudo-odwrotną Moora-Penrose'a.

Z powyższych równań wynika, że jedyną nieznaną wielkością niezbędną do wyznaczenia centralnej, łącznej estymaty stanu $\hat{x}^c(k|k)$ jest kowariancja (24). Kowariancję tę można wyznaczać korzystając z przedstawionego poniżej równania.

Pomijając indeks i dotyczący ośrodka lokalnego, błąd estymacji w każdym ośrodku lokalnym opisać można następującym równaniem rekurencyjnym:

$$\begin{aligned} \tilde{x}(k|k) &= x(k) - \hat{x}(k|k) = x(k) - (\hat{x}(k|k-1) + W(k)v(k)) \\ &= x(k) - \hat{x}(k|k-1) - W(k)(z(k) - \hat{z}(k|k-1)) \\ &= x(k) - \hat{x}(k|k-1) - W(k)[Hx(k) + w(k) - H\hat{x}(k|k-1)] \\ &= (I - W(k)H)(x(k) - \hat{x}(k|k-1)) - W(k)w(k) \\ &= (I - W(k)H)(Fx(k-1) + Gu(k-1) - F\hat{x}(k-1|k-1)) + \\ &\quad - W(k)w(k) \\ &= (I - W(k)H)(F(x(k-1) - \hat{x}(k-1|k-1)) + Gu(k-1)) + \\ &\quad - W(k)w(k) \\ &= (I - W(k)H)(F\tilde{x}(k-1|k-1) + Gu(k-1)) - W(k)w(k). \end{aligned} \quad (28)$$

Elementy macierzy kowariancji $\text{cov}\{\gamma(k)\}$ (24) można wyznaczyć w sposób opisany poniżej, wyróżniając dwa przypadki. W przypadku pierwszym, gdy $i=j$, elementy z głównej przekątnej macierzy $\text{cov}\{\gamma(k)\}$ wyznaczone są przez lokalne filtry Kalmana i wynoszą:

$$E\{\tilde{x}^i(k|k)(\tilde{x}^i(k|k))^T\} = P^i(k|k), \quad (29)$$

gdzie macierz $P^i(k|k)$ opisana jest równaniem (17).

W drugim przypadku, gdy $i \neq j$, elementy macierzy $\text{cov}\{\gamma(k)\}$ można wyznaczyć rekurencyjnie na podstawie (28) w następujący sposób:

$$\begin{aligned} E\{\tilde{x}^i(k|k)(\tilde{x}^j(k|k))^T\} &= (I - W^i(k)H)F \cdot \\ &\cdot E\{\tilde{x}^i(k-1|k-1)(\tilde{x}^j(k-1|k-1))^T\}F^T(I - W^j(k)H)^T + \\ &+ (I - W^i(k)H)Q(I - W^j(k)H)^T. \end{aligned} \quad (30)$$

Przy założeniu, że pomiary w ośrodkach lokalnych są wzajemnie niezależne, oraz, że trajektoria w każdym ośrodku jest inicjalizowana na podstawie danych niezależnych od innych ośrodków, jako wartości początkowe elementów macierzy $\text{cov}\{\gamma(k)\}$ można przyjąć macierze zerowe o odpowiednim rozmiarze, tj.

$$E\{\tilde{x}^i(0|0)(\tilde{x}^j(0|0))^T\} = [0], \quad i \neq j. \quad (31)$$

5. Przykład symulacyjny i wnioski

Przebadano problem wyznaczania trajektorii poruszającego się obiektu. Przyjęto model obiektu i równanie obserwacji wprowadzone w rozdziale 2. Macierz kowariancji procesu $u(k)$ wynosiła:

$$U = \begin{bmatrix} 0,25 & 0 \\ 0 & 0,25 \end{bmatrix} \quad (32)$$

Stan obiektu estymowany był przez dwa ośrodki lokalne. Okres próbkowania czujników wynosił $T=1[s]$, natomiast macierze kowariancji procesu $w(k)$ wynosiły odpowiednio:


$$R^1 = \begin{bmatrix} 14,4 & 0 \\ 0 & 14,4 \end{bmatrix}, \quad (33)$$

oraz

$$R^2 = \begin{bmatrix} 4,9 & 0 \\ 0 & 4,9 \end{bmatrix}. \quad (34)$$

Mniejsze wartości elementów na głównej przekątnej w macierzy R^2 niż w macierzy R^1 oznaczają, że czujnik skojarzony z drugim estymatorem dokonywał pomiaru z większą dokładnością niż czujnik skojarzony z pierwszym estymatorem.

Poniższe wyniki są średnią ze 100 niezależnych przebiegów symulacji. Na rys. 2 przedstawiono średnią wartość bezwzględną błędów estymacji położenia obiektu dla obu estymatorów lokalnych i dla systemu centralnego opartego na zaprezentowanym algorytmie.




Rys. 2. Błędy wyznaczania położenia obserwowanego obiektu
Fig. 2. Position estimation errors for the object observed

Błąd estymacji zdefiniowany jest jako różnica pomiędzy wartością prawdziwą (która była znana dla eksperymentu symulacyjnego) a wartością otrzymaną z estymatora.

Jako wartość początkową dla algorytmów estymacji przyjęto prawdziwą wartość stanu obiektu obciążoną pewnym błędem. Symuluje to niepewność wyznaczania stanu początkowego przez algorytm inicjalizacji trajektorii (problem inicjalizacji trajektorii nie jest tu rozpatrywany). Jak widać na rysunku system centralny wyznacza położenie obserwowanego obiektu z mniejszym błędem niż poszczególne estymatory lokalne.

Na rys. 3 przedstawiono średnią wartość bezwzględną błędu wyznaczania prędkości obserwowanego obiektu. Podobnie jak w przypadku wyznaczania położenia system centralny dokonuje estymacji bardziej dokładnie. Jednak w tym przypadku wyniki dla systemu centralnego oraz estymatora 2 są zbliżone. Jest to w znacznej mierze spowodowane tym, że prędkość obserwowanego obiektu nie była bezpośrednio mierzona przez czujniki.




Rys. 3. Błędy wyznaczania prędkości obserwowanego obiektu
Fig. 3. Velocity estimation errors for the object observed


Koleją symulację wykonano w celu przebadania pracy algorytmu centralnego w przypadku, gdy zachodzą duże zmiany rzeczywistej prędkości obiektu. Z wyjątkiem kowariancji procesu $u(k)$, którą zmieniono na

$$U = \begin{bmatrix} 9,0 & 0 \\ 0 & 9,0 \end{bmatrix}, \quad (35)$$

wszystkie pozostałe parametry symulacji pozostawiono bez zmian. Wyniki estymacji (tj. średnia wartość bezwzględna błędu wyznaczania położenia oraz prędkości) przedstawiono na rys. 4 i rys 5. Wnioski wynikające z tego przykładu estymacji są takie same jak w przypadku poprzedniej sytuacji (z symulowaną mniejszą zmianą prędkości poruszania się obiektu).



Rys. 4. Błędy wyznaczania położenia w przypadku dużych zmian prędkości obserwowanego obiektu
Fig. 4. Position estimation errors in the case of large velocity changes of the object observed



Rys. 5. Błędy wyznaczania prędkości w przypadku dużych zmian prędkości obserwowanego obiektu
Fig. 5. Velocity estimation errors in the case of large velocity changes of the object observed

6. Podsumowanie

W pracy rozważano rozproszony synchroniczny system estymacji stanu, która nie jest wykonywana w jednym ośrodku centralnym, ale w wielu ośrodkach lokalnych w oparciu o podzbiór danych dostępny lokalnie. Zwykle w rozproszonych sieciach czujników nie istnieje żaden element nadrzędny. Jednak w niektórych systemach informacja zbierana przez czujniki może być wykorzystywana przez pewien system „centralny”, typu baza danych lub algorytm sterowania. Taką właśnie funkcję pełni prezentowany centralny system fuzji trajektorii obiektów poruszających się w obserwowanej przestrzeni.

Autorzy prowadzą badania nad fuzją danych w asynchronicznym systemie estymacji stanu. W systemie takim, każdy z ośrodków lokalnych wyznacza estymaty stanu w dowolnych chwilach czasu, zaś ośrodek centralny dokonuje odpowiedniej fuzji estymat w chwilach czasu, które są niezależne od momentów obliczeniowych estymatorów lokalnych. Niniejsza praca stanowi zatem wstępną fazę badań algorytmów fuzji danych, również bez uwzględniania wpływu opóźnień bądź utraty danych w kanałach transmisyjnych.

7. Literatura

- [1] Y. Bar-Shalom, X.R. Li: Estimation and Tracking: Principles, Techniques, and Software. Artech House, Boston, MA, 1993.
- [2] Y. Bar-Shalom, X.R. Li: Multitarget-Multisensor Tracking: Principles and Techniques. CT:YBS Publishing, Storrs, 1995.
- [3] R.E. Kalman: A new approach to linear filtering and prediction problems. Transactions of the ASME, Journal of Basic Engineering, 82, pp. 34–45, March 1960.
- [4] D. Smith, S. Singh: Approaches to Multisensor Data Fusion in Target Tracking: A Survey. IEEE Transactions on Knowledge and Data Engineering, 18(12):1696–1710, December 2006.
- [5] Z. Kowalczyk, M. Domżański: Asynchronous distributed fusion for state estimation of dynamic objects. In: Proc. 11th IEEE International Conference on Methods and Models in Automation and Robotics, Miedzyzdroje, Poland, September 2005.
- [6] Z. Kowalczyk, M. Domżański: Estimation of multiple trajectories in asynchronous distributed tracking systems. In: Proc. 13th IEEE IFAC International Conference on Methods and Models in Automation and Robotics, Szczecin, Poland, September 2007.
- [7] X.R. Li: Optimal linear estimation fusion — Part VII: Dynamic systems. In: International Conference on Information Fusion, pp. 455–462, Cairns, Australia, July 2003.
- [8] X.R. Li, Y.M. Zhu, J. Wang, C.Z. Han: Optimal linear estimation fusion — Part I: Unified fusion rules. IEEE Transactions on Information Theory, 49(9): 2192–2208, September 2003.