

Grzegorz Reyman

Politechnika Wrocławska
Instytut Sterowania i Techniki Systemów

ZASTOSOWANIE ALGORYTMÓW ROZPOZNAWANIA W SYSTEMIE MONTAŻOWYM Z ROBOTEM STERUJĄCYM

Streszczenie. W artykule przedstawiono model systemu montażowego z robotem sterującym. Algorytm sterowania robotem montażowym został zdekomponowany na dwa etapy. Na pierwszym etapie rozpoznany zostaje aktualny stan systemu montażowego, a na drugim etapie algorytm wyznacza kolejną operację do wykonania.

1. Wstęp

W ostatnich latach wzrasta zainteresowanie produkcją krótko i długoseryjną. Jest to spowodowane względami ekonomicznymi. W tego typu produkcji znajdują zastosowanie manipulatory sterowane cyfrowo, a zwłaszcza roboty przemysłowe. W niniejszej pracy interesować nas będą roboty montażowe, które podczas mechanicznego montażu muszą rozwiązywać złożone zadania z wieloma nieznanymi parametrami, których nieznaną jest spowodowana między innymi zmiennym środowiskiem pracy robota, brakami technologicznymi montowanych części, przypadkowością w napływie i położeniu elementów do montażu. Wielu autorów próbowało rozwiązać problem montażu przez robot posiadający sztuczną inteligencję.

Ejiri i inni [1] zaproponowali system z kamerami TV. Montaż odbywał się w oparciu o rozpoznawanie leżących bloków prostopadłościennych i na montowaniu ich według rysunku technicznego. Coiffet i Rives [2] opisali problemy występujące przy montowaniu elementów o kształcie piramidy. Każdy element o tym kształcie, pojawiający się w przestrzeni roboczej, mógł być montowany tylko wówczas, gdy leżał na odpowiedniej ścianie. Jeśli jednak jego położenie było inne, to robot musiał zdecydować, czy pchnąć przypadkowo piramidę, czy też wyliczyć punkt pchnięcia w oparciu o kosztowną analizę aktualnej sytuacji.

Grossman i Blasgen [3] opisali prosty problem montażu z zastosowaniem, tzw. pudełka orientującego. Dodatkowy manipulator wrzucał przypadkowo wybrane elementy do wibrującego pudełka, które przestawało wibrować, gdy element przyjął stałą pozycję w jego dolnym rogu. Następnie robot dokonywał pomiaru i na jego podstawie decydował czy element jest dobrze zorientowany do uchwycenia i montażu, czy należy go przemieścić w pudełku i po następnej wibracji zbadać ponownie jego położenie, czy też dokonać pracochłonnej

analizy i przemieścić element do pożądanej pozycji. Przykład montażowy podany w pracy będzie rozwinięciem tego pomysłu. Birk i Kelley [4] opisali system z kamerami TV, gdzie po analizie aktualnego obrazu pudełka z elementami, robot decydował gdzie i jak uchwycić jeden z elementów w pudełku.

Ogólniejsze heurystyczne opisy planowania montażu elementów o płaskich ścianach można znaleźć w pracy Fahlman'a [5] i Paul'a [6]. Ogólne podejście do optymalizacji pracy robota montażowego zostało zaprezentowane w pracy Reymana [7]. Jednak takie optymalne algorytmy są zbyt złożone obliczeniowo aby mieć zastosowanie do procesów montażowych, gdzie decyzje muszą być podejmowane bardzo szybko. W związku z tym w niniejszej pracy rezygnuje się z optymalności algorytmów dla robota montażowego na rzecz znacznego ich uproszczenia.

2. Matematyczne sformułowanie problemu

Stany systemu montażowego można ponumerować i wówczas dostaje się skończony zbiór indeksów stanów $S = \{1, 2, \dots, M\}$. W każdej chwili n robot musi wybrać jedną z operacji ze zbioru operacji dopuszczalnych. Jeśli operacje zostaną również ponumerowane, to dostaniemy zbiór indeksów dopuszczalnych operacji $K = \{1, 2, \dots, l\}$. Wykonanie każdej z operacji powoduje zmianę stanu systemu. Te zmiany stanów mogą być opisane za pomocą prawdopodobieństw przejść. Zakładamy, że przejścia są opisywane przez jednorodny sterowany łańcuch Markowa

$$P_{ij}^k = P(j_{n+1}=j | j_n=i, k), \quad i, j \in S, \quad k \in K, \quad /1/$$

gdzie j_n , $n=0, \dots, N$ jest dyskretną zmienną losową, a k jest indeksem operacji podjętej w chwili n .

Stany są mierzone niedokładnie i proponuje się ogólny opis urządzenia pomiarowego za pomocą warunkowych funkcji gęstości

$$f(x_n | j), \quad j \in S, \quad x_n \in E^r. \quad /2/$$

Zakładamy aprioryczną znajomość prawdopodobieństw przejść, jakkolwiek mogą być one łatwo estymowane na podstawie odpowiednich częstości [7].

Funkcje gęstości będą estymowane na podstawie zbioru ciągów uczących

$$A_{m_j} = \{x_1^j, x_2^j, \dots, x_{m_j}^j\}, \quad /3/$$

gdzie x_n^j jest wynikiem n -tego pomiaru stanu systemu $j_n = j$. Każdy z ciągów uczących A_{m_j} jest wybrany z ciągu uczącego A_m wszystkich po-

miarów, gdzie m jest ilością tych pomiarów. W związku z modelem /2/ urządzenia pomiarowego, wyniki pomiarów ciągu A_m , są niezależne losowo.

W pracy [7] przyjęto za kryterium jakości sterowania robotem montażowym wartość oczekiwaną sumy kosztów kolejnych przejść w zadanym horyzoncie czasowym N

$$Q_N = E \sum_{n=0}^{N-1} c_n(j_n, k_n), \quad /4/$$

gdzie $c_n(j_n, k_n)$ są dodatnimi kosztami użycia operacji o indeksie $k_n \in K$, gdy aktualny stan jest $j_n \in S$, w chwili $n=0, 1, \dots, N-1$.

W niniejszej pracy zakładając będziemy stacjonarność kosztów ze względu na zastosowanie kryterium /4/.

Jako kryterium jakości rozpoznawania aktualnej sytuacji technologicznej w [7] przyjęto ryzyko Bayesa

$$R_N = E \sum_{n=0}^{N-1} L_n(i_n; j_n), \quad /5/$$

gdzie L_n jest lokalną zero-jedynkową funkcją strat, a $i_n \in S$ jest rozpoznany stanem $i_n = \psi_n(x_n; e_{n-1})$, gdzie e_{n-1} jest historią procesu montażowego, $e_n = (e_{n-1}; x_n, k_n)$.

W pracy [7] rozpatrzono algorytm sterowania bezpośredniego w oparciu o aktualny pomiar stanu x_n minimalizujący kryterium /4/ oraz algorytm dwuetapowy, rozpoznający aktualny stan i_n , minimalizujący kryterium /5/ a następnie sterujący w oparciu o rozpoznany stan wg kryterium /4/.

W algorytmie tym brano pod uwagę prawdopodobieństwa błędnego rozpoznania stanu. Pokazano zbieżność obu algorytmów w przypadku, kiedy opis /1/, /2/ jest nieznanymi a odpowiednie estymatory funkcji gęstości są wyznaczane na podstawie ciągów uczących /3/.

W obecnej pracy zakładamy jedynie znajomość prawdopodobieństw przejść /1/ i ciągów uczących /3/. Rozważane są algorytmy dwuetapowe. Pierwszym etapem jest rozpoznanie aktualnego stanu systemu montażowego i_n , a następnym sterowanie w oparciu o ten stan, z tym, że dla algorytmu sterowania zakładając będziemy równoważność: $j_n = i_n$ czyli, że stan jest rozpoznawany bezbłędnie. Prowadzi to oczywiście do straty optymalności tak zbudowanych algorytmów, ale w ten sposób bardzo znacznie skraca się obliczenia, co jest celem pracy.

Będziemy rozważać cztery algorytmy rozpoznawania. Algorytm 1 jest bayesowskim algorytmem rozpoznawania minimalizującym ryzyko /5/. Algorytm 2 jest bayesowskim algorytmem rozpoznawania minimalizującym lokalne ryzyko

$$R_n = E L_n(i_n; j_n), \quad /6/$$

a więc nie bierze pod uwagę charakteru procesu montażowego. Algorytm 3 to algorytm najbliższego sąsiada: 1-NN. Algorytm 4 to algorytm dwóch naj-

bliższych sąsiadów : 2-NN .

3. Rezultaty

Druga część algorytmu bazuje na dobrze znanych rezultatach [9] , [10] .
Stosując programowanie dynamiczne Bellmana dla kryterium /4/ algorytm sterowania systemem /1/ jest następujący

$$V_0(j_N) = 0 \quad /7/$$

$$V_1(j_{N-1}) = \min_{k \in K} c_{N-1}(j_{N-1}, k) \quad /8/$$

$$V_{N-n}(j_n) = \min_{k \in K} c_n(j_n, k) + \sum_{j_{n+1}=1}^M V_{N-n-1}(j_{n+1} P_{ij}^k) , \quad /9/$$

gdzie po minimalizacji dla każdego etapu n otrzymamy tabelę sterowań, podającą którą operację należy wykonać jeśli system znajdzie się w stanie j_n .

Rezultaty dla algorytmów rozpoznawania są następujące;

Algorytm 1:

$$i_n = \psi_n^1(x_n; e_{n-1}, A_n) , \quad /10/$$

gdy

$$d_n(i_n, x_n; e_{n-1}, A_m) > d_n(1, x_n; e_{n-1}, A_m) ,$$

gdzie $1 = 1, 2, \dots, i_{n-1}, i_{n+1}, \dots, M$

$$d_n(1, x_n; e_{n-1}, A_m) = \sum_{j_{n-1}=1}^M \hat{f}(x_n|1) \cdot p_{j_{n-1}}^k \cdot d_{n-1}(j_{n-1}, x_{n-1}; e_{n-2}, A_m) /11/$$

z warunkiem początkowym

$$d_0(1, x_0; A_m) = p_1 \cdot \hat{f}(x_0|1) ,$$

gdzie p_1 są prawdopodobieństwami początkowymi stanów $1, 1 \in S$.

$\hat{f}(x_n|1)$ jest estymatorem funkcji gęstości $f(x_n|1)$ uzyskiwanym na podstawie ciągów uczących A_m /3/.

W pracy [7] pokazano, że estymator Parzena $f(x_n|1)$ z jądrem w postaci eksponencjalnej jest mocno zgodny i w związku z tym algorytm /10/ jest również mocno zgodny.

Algorytm 2:

$$i_n = \psi^2(x_n; A_m) \quad /12/$$

gdy

$$p_{i_n} \cdot f(x_n | i_n) > p_1 \cdot f(x_n | 1),$$

gdzie $1 = 1, 2, \dots, i_n - 1, i_n + 1, \dots, M$.

Oczywiście, jeśli estymator $f(x_n | j)$ jest zgodny, to także algorytm /12/ jest zgodny [8].

Algorytm 3 i Algorytm 4 to znane algorytmy 1-NN i 2-NN, których opis własności można znaleźć w pracach [7], [12].

4. Rezultaty symulacyjne

Rozważmy prosty przykład systemu montażowego z jednym robotem i jednym manipulatorem. Manipulator wyjmuje z pudełka z częściami przypadkowo ułożone elementy i wkłada je do pudełka orientującego. Pudełko wibruje przez chwilę, aż do momentu, gdy element znajdzie się w jego dolnym rogu. Wówczas dwa urządzenia pomiarowe umieszczone równolegle do dwóch krawędzi pudełka dokonują pomiaru dwóch wielkości x^1 i x^2 , które tworzą wektor pomiarowy x . Mikroprocesor robota dokonuje analizy pomiaru i wybiera jedną z następujących operacji:

k=1 : montuj,

k=2 : przewróć,

k=3 : przesunąć,

k=4 : dokonaj reorientacji w oparciu o współpracę z EMC.

Oczywiście operacja k=4 jest najbardziej czasochłonna i najdroższa.

Element w pudełku orientacyjnym może być w jednym z 3 stanów:

j=1 : element dobrze zorientowany do montażu,

j=2 : element musi być odwrócony na drugą stronę,

j=3 : element nie musi być odwrócony.

Stan elementu j=3 oznacza, że wystarczy go przesunąć /następuje ponowna wibracja/, aby uzyskać pożądane położenie.

Dokonano następujących badań symulacyjnych.

Pierwsza seria badań dla wszystkich algorytmów badała ważoną różnicę średnich kosztów w stosunku do kosztu optymalnego algorytmu sterowania bezpośredniego, opisanego w pracy [7]. Badania wykonano dla różnych wzajemnych położenia śladów warunkowych funkcji gęstości $f(x|1)$ przy ustalonych dwóch różnych wartościach kontekstowości łańcucha Markowa w sensie wartości parametru g

$$g = \frac{1}{K(M-1)^2} \sum_{k=1}^K \sum_{j=1}^{M-1} \sum_{\{1,1\}} (p_{1j}^k - p_{1j}^k)^2, \quad /13/$$

gdzie $\{1,1\}$ jest zbiorem wszystkich możliwych par $(1,1)$, $1,1 \in S$.

Wzajemne położenie śladów warunkowych funkcji gęstości wyrażono parametrem

$$b = \sum_{\{1,k\}} \int_{E^r} f(x|1) \cdot f(x|k) \cdot dx \quad /14/$$

Uzyskano następujące wyniki.

Dla małych wartości g / $g < 0.3$ /, czyli małej wartości kontekstowości łańcucha Markowa, dla $b \in (0.0, 0.2)$ rezultaty wszystkich algorytmów są takie same. Dla $b \in (0.2, 0.7)$ najlepsze rezultaty daje Algorytm 2 i Algorytm 4, zastosowane na pierwszym etapie z algorytmem sterowania /9/ na drugim etapie. Najgorsze rezultaty daje zastosowanie na pierwszym etapie algorytmu 1-NN, gdyż opiera się on na zbyt małej informacji z A_m . Dla $b > 0.7$ jakość wszystkich algorytmów gwałtownie pogarsza się z tym, że najlepszy jest Algorytm 1.

Dla wartości g znacznie większej / $g = 0.7$ / wyniki wyraźnie zmieniają się na korzyść Algorytmu 1 stosowanego z algorytmem /9/. Dzieje się tak, gdyż tylko ten algorytm wykorzystuje informację o dużej zależności Markowa w systemie /1/.

5. Uwagi końcowe

Wyniki eksperymentu symulacyjnego wskazują, że bardzo istotną sprawą dla systemów montażowych z robotem o sztucznej inteligencji jest dobór punktów pomiarowych. Dobór ten bowiem determinuje postać warunkowych funkcji gęstości $f(x|j)$.

Z porównania algorytmów wynika, że najlepiej jest stosować algorytm najbliższego sąsiada, 1-NN. O ile algorytmy on-line proponowane w pracy /7/ miały złożoność obliczeniową $O(r^2 M^4 m)$, to algorytm sterowania z zastosowaniem algorytmu 1-NN ma złożoność obliczeniową $O(r M m)$, a z zastosowaniem algorytmu 2-NN odpowiednio $O(r M m^2)$. Oczywiście, kiedy wzrasta wartość parametru g /zależność Markowa w systemie /1/ /, to najlepsze rezultaty daje algorytm sterowania z wykorzystaniem Algorytmu 1 na pierwszym etapie. Jednak ten algorytm ma stosunkowo dużą złożoność obliczeniową $O(r M^3 m)$, a więc należy sensownie w zależności od obydwu wskaźników dla danego systemu montażowego / g i b / oraz wymaganego maksymalnego czasu na decyzję dla robota montażowego, wybrać jeden z podanych algorytmów.

LITERATURA

- [1] M.Ejiri et al., "A Prototype Intelligent Robot that Assembles Objects from Plane Drawings", IEEE Trans. Computers, vol. C-21, No 2, pp. 161-170, 1972.
- [2] P.Coiffet, P.Rives, "Reconnaissance par un Robot de L'orientation d'objects tridimensionnel en vue de Taches de saisie automatique", RAIRO, vol. 14, No 1, pp. 5-32, 1973.
- [3] D.D.Grossman, M.W.Blasgen, "Orienting Mechanical Parts by Computer Controlled Manipulator", IEEE Trans. Syst. Man Cybern. vol. SMC-5, No 5, pp.561-565, 1975.

- [4] R. Kelley et al., "A Robot System which Acquires Cylindrical Workpieces from Bins", IEEE Trans. Syst. Man Cybern., vol. SMC-12, No 12, pp.204-213, 1982.
- [5] S.E. Fahlman, "A Planning System for Robot Construction Tasks", Artificial Intelligence, vol. 5, pp. 1-49, 1974.
- [6] R. Paul, "WAVE. A model based language for manipulator control", The Industrial Robot, pp. 10-17, March 1977.
- [7] G. Reyman, "General Approach to Assembly Robot Control", Advanced Software in Robotics Conference, Liege, May 1983, North-Holland.
- [8] W. Greblicki, "Asymptotically Optimal Pattern Recognition Procedures with Density Estimates", IEEE Trans. Inf. Theory, vol. IT-24, No 2, pp. 250-251, 1978.
- [9] H. Kushner, "Introduction to Stochastic Control", Holt, Rinehart and Winston, Inc., New York 1971.
- [10] C. Derman, "Finite State Markovian Decision Processes", Academic Press, New York and London 1970.
- [11] T.M. Cover, P.E. Hart, "Nearest Neighbor Pattern Classification", IEEE Trans. Inf. Theory, vol. IT-13, No 1, pp. 21-27, 1967.
- [12] T.J. Wagner, "Convergence of the Nearest Neighbor Rule", IEEE Trans. Inf. Theory, vol. IT-17, No 5, pp.566-571, 1971.

Recenzent: Prof. dr hab. inż. Antoni Woźniak

Wpłynęło do Redakcji do 30.03.1984r.

ПРИМЕНЕНИЕ АЛГОРИТМОВ РАСПОЗНАВАНИЯ В МОНТАЖНОЙ СИСТЕМЕ С УПРАВЛЯЮЩИМ РОБОТОМ

Резюме

В статье представлена монтажная система с управляющим роботом. Алгоритм управления робота декомпонирован на два этапа. На первом этапе распознаётся актуальное состояние монтажной системы. На втором этапе, на основании распознанного состояния, алгоритм определяет очередную операцию, которая должна быть выполнена роботом. Сравниваются подходы для разных алгоритмов распознавания на первом этапе. Произведён сравнительный анализ для переменных значений индекса, определяющего способ измерения состояний системы.

AN APPLICATION OF PATTERN RECOGNITION ALGORITHMS IN THE ASSEMBLY SYSTEM WITH A ROBOT

Summary

The assembly system model is presented in the paper. A control algorithm for the robot has been decomposed into two stages. The actual system state is recognized in the first stage. The operation to be performed by the robot is determined on the basis of the recognized state in the second stage. Approaches using different recognition algorithms in the first stage are compared. This analysis has been made for different ways of system state measuring.