

REGULATOR ROZMYTY TAKAGI-SUGENO W STEROWANIU ADAPTACYJNYM ROBOTEM MOBILNYM

Opisano mały trójkołowy robot mobilny skonstruowany w Katedrze Automatyki i Informatyki Politechniki Rzeszowskiej. Zaprezentowano układ nawigacyjny realizujący zadanie poszukiwania celu. Rolę regulatora adaptacyjnego pełni regulator rozmyty Takagi - Sugeno. Uczenie regul odbywa się w oparciu o algorytm wstecznej propagacji błędu adoptowany dla potrzeb uczenia ze wzmocnieniem. Algorytmy sprawdzono eksperymentalnie.

Takagi-Sugeno fuzzy controller in adaptive control of a mobile robot.

A small three-wheeled mobile robot assembled in Control and Computer Engineering Department at Rzeszow University of Technology is described. A navigation system performing the goal seeking task is presented. As an adaptive controller, the Takagi-Sugeno fuzzy system is used. The fuzzy control rules are obtained using the back-propagation algorithm adopted for reinforcement learning. The control algorithms was experimentally verified.


1. WSTĘP

Od początku lat 80-tych w wielu dziedzinach przemysłu oraz w sprzęcie gospodarstwa domowego odnotowuje się zwiększone zainteresowanie logiką rozmytą. Można ją odnaleźć w pralkach, lodówkach, kamerach VHS i „inteligentnych” odkurzaczach ale również w kolejce w Sendai (Japonia) gdzie z powodzeniem zastąpiła doświadczonego maszynistę [4, 5]. Istotnym problemem w sterowaniu z wykorzystaniem logiki rozmytej są reguły, które najczęściej podaje „ekspert” posiadający pewną wiedzę o obiekcie sterowania [1]. Istnieją już metody off - line doboru reguł dla obiektów o znanym modelu analitycznym [2]. W niniejszym artykule zaprezentowano metodę on - line doboru wartości sterowań regulatora rozmytego Takagi-Sugeno sterującego laboratoryjnym robotem mobilnym realizującym zadanie poszukiwania celu.

Obiektem sterowania był laboratoryjny robot mobilny opisany w rozdziale 2. W rozdziale 3 przedstawiono układ sterowania realizujący zadanie poszukiwania celu, rozdział 4 opisuje zastosowany regulator rozmyty, rozdział 5 poświęcono algorytmowi uczenia ze wzmocnieniem. W rozdziale 6 zamieszczono wyniki przeprowadzonych eksperymentów.

2. ROBOT MOBILNY - BARREL

Robot trójkątowy **Barrel** (fot. 1.), został zaprojektowany i wykonany w Katedrze Automatyki i Informatyki Politechniki Rzeszowskiej. Robot jest wykorzystywany do badań naukowych i w dydaktyce. Pozwala na to solidna budowa mechaniczna oraz zasilanie z akumulatorów o dużej pojemności.



Fot. 1. Robot mobilny **Barrel**

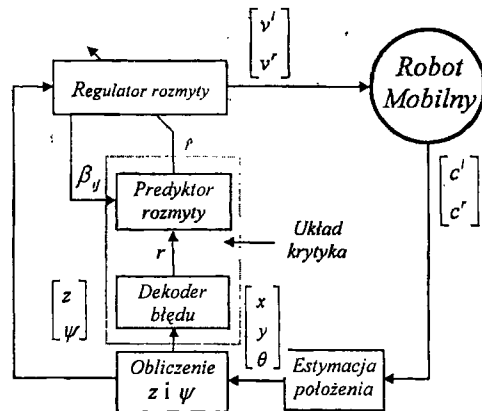
Protokół komunikacji pomiędzy PC, a robotem mobilnym został specjalnie zmodyfikowany, tak by był kompatybilny z protokołem komunikacyjnym miniaturowego robota mobilnego Khepera. Ze względu na odmienną budowę sprzętową, lista rozkazów Khepery jest podzbiorem rozkazów protokołu robota **Barrel**. Specjalny rozkaz włącza przeliczanie naturalnych dla robota **Barrel** jednostek położenia serwomechanizmów na jednostki Khepery. Pozwala to na szybkie przeniesienie algorytmów sterowania przetestowanych w robocie Khepera i odwrotnie. Stworzone jest więc środowisko pozwalające na weryfikowanie algorytmów sterowania w pewnej klasie robotów mobilnych. Robot ma cylindryczny kształt o promieniu 300mm. Wyposażony jest w trzy koła: dwa napędowe i koło wodzone. Z przodu robota umieszczono 8 odbiciowych czujników zbliżeniowych SCOO-200RP, pracujących w paśmie podczerwieni i posiadających możliwość regulacji zasięgu wykrywania przeszkód. Ze względu na binarne wyjście czujnika, konieczne stało się zastosowanie prototypowej techniki "rozmywania w czasie" - zamieniającej wartość binarną na pseudoanalogową [6].

Robot sterowany jest zespołem wieloprocesorowym. Procesorem nadrzędnym układu sterowania jest mikrokomputer jednoukładowy 80C535, a sterowanie serwomechanizmami układu jezdnego i pomiaru położenia osi koła wodzonego realizują specjalizowane procesory - sterowniki ruchu LM629.

3. UKŁAD STEROWANIA

Zadaniem regulatora rozmytego opisanego w następnym rozdziale będzie doprowadzenie robota do celu (rys. 2), czyli minimalizowanie odległości $z = \|X_g - X\|$ ($\|\cdot\|$ - norma

Euklidesowa) robota od celu. $X = [x, y]$ oznacza pozycję robota w globalnym układzie współrzędnych (X, Y) ; $X_g = [x_g, y_g]$ - współrzędne celu; θ - orientację robota; ψ - odchylenie robota od celu ($\psi = \theta - \arctan \frac{y_g - y}{x_g - x}$), a R - promień robota ($R = 26mm$).



Rys. 3. Układ sterowania

Na rys. 3 przedstawiono schemat adaptacyjnego układu sterowania robotem, realizującego zadanie poszukiwania celu. Na podstawie drogi pokonanej przez poszczególne koła (c^l i c^r) układ *estymacji położenia* szacuje współrzędne robota $[x, y, \theta]$. Następnie obliczane są zmienne wejściowe *regulatora rozmytego* z i ψ (rozdz. 4). Ponadto, na podstawie odchylenia robota od celu (kąta ψ) i odległości robota od celu (z) *dekoder błędu* wraz z *predyktorem rozmytym* wyznacza sygnał wzmocnienia \hat{r} , który jest podstawą algorytmu *uczenia ze wzmocnieniem*, opisanego w rozdz. 5. Na zakończenie cyklu pracy układu regulacji *regulator rozmyty* na podstawie uaktualnionych wartości następników reguł c_m (rozdz. 4.) wyznacza wartości sterowań, tj. prędkości lewego koła (v^l) i prawego koła (v^r).

4. REGULATOR ROZMYTY

Wyjście rozmytego regulatora Takagi-Sugeno w przypadku niesprzecznego i zupełnego systemu reguł sterowania obliczane jest na podstawie tablicy reguł (Tab. 1) według następującej zależności [1]:

$$v^k = \frac{\beta_1 c_{k1} + \dots + \beta_n c_{kn} + \dots + \beta_6 c_{k6}}{\beta_1 + \dots + \beta_n + \dots + \beta_6}, \quad (1)$$

gdzie współczynniki β_n wyrażają się wzorem:

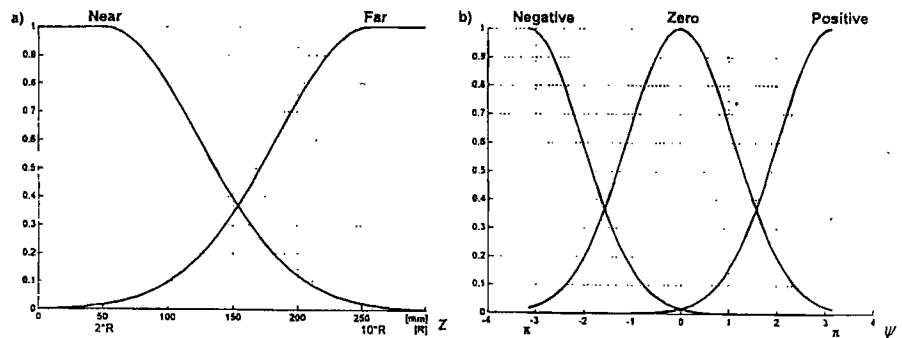
$$\beta_n = A_{1n}(z) \cdot A_{2n}(\psi), \quad (2)$$

natomiast $A_{1n}(z)$ i $A_{2n}(\psi)$ są stopniami przynależności odpowiednio wejść z i ψ do zbiorów rozmytych A_{1n} i A_{2n} , a c_m - wartościami sterowań (prędkościami sterującymi odpowiednio lewym i prawym kołem) z tablicy reguł (Tab. 1). Ponadto $n=1, \dots, N$ jest

numerem reguły, zaś $k=l,r$ - indeksem wyjścia regulatora odpowiednio dla lewego i prawego koła.

z	ψ	c_{ln}	c_{rm}
A_{11} (Near)	A_{11} (Negative)	c_{l1}	c_{r1}
A_{12} (Near)	A_{12} (Zero)	c_{l2}	c_{r2}
A_{13} (Near)	A_{13} (Positive)	c_{l3}	c_{r3}
A_{14} (Far)	A_{14} (Negative)	c_{l4}	c_{r4}
A_{15} (Far)	A_{15} (Zero)	c_{l5}	c_{r5}
A_{16} (Far)	A_{16} (Positive)	c_{l6}	c_{r6}

Tab. 1. Tablica reguł.



Rys. 4. Wejściowe funkcje przynależności dla: a) odległości robota od celu z , b) odchylenia od celu ψ .

Zaproponowano dwa zbiory rozmyte (*Near* i *Far*) dla zmiennej z i trzy zbiory dla zmiennej ψ (*Negative*, *Zero* i *Positive*) (rys. 4). Liczba reguł oraz wejściowe funkcje przynależności, które dobrano na zasadzie równomiernego podziału dziedziny zmiennych wejściowych z i ψ , będą niezmiennie. Uczeniu wzmocnionemu będą podlegały wartości sterowań c_{lr} .

5. UCZENIE ZE WZMOCNIENIEM

5.1. Algorytm spadku gradientu uczenia sterowań regulatora Takagi - Sugeno

Celem uczenia będzie minimalizowanie funkcji kary

$$E = \frac{1}{2} \sum_{k=l,r} (v_k(t) - \hat{v}_k(t))^2, \quad (3)$$

gdzie $\hat{v}_k(t)$ jest pożądanym, zaś $v_k(t)$ - aktualnym k -tym wyjściem sieci w czasie t . Do uczenia zastosowano metodę gradientową, w której uaktualnianie wag (wartości sterowań c_{kn}) odbywa się zgodnie z zależnościami (4), (5)

$$c_{kn}(t+1) = c_{kn}(t) + \eta \cdot \left(-\frac{dE(c_{kn})}{dc_{kn}} \right), \quad (4)$$

$$\frac{dE}{dc_{kn}} = \frac{d}{dc_{kn}} \left[\frac{1}{2} \sum_{k=i,r} (v_k - \hat{v}_k)^2 \right] = (v_k - \hat{v}_k) \frac{\beta_n}{\sum_{n=1}^N \beta_n}. \quad (5)$$

gdzie η jest współczynnikiem uczenia.

Podstawiając równania (5) do równania (4) otrzymamy rekurencyjną zależność uczenia wartości sterowań c_{kn} regulatora rozmytego Takagi-Sugeno zapewniającą minimalizację funkcji kary (3)

$$c_{kn}(t+1) = c_{kn}(t) + \eta \cdot \frac{\beta_n}{\sum_{n=1}^N \beta_n} (\hat{v}_k(t) - v_k(t)). \quad (6)$$

5.2. Adaptacja metody uczenia ze wzmocnieniem do algorytmu wstecznej propagacji błędu uczenia parametrów regulatora Takagi-Sugeno

Dyskusję algorytmu uczenia ze wzmocnieniem przedstawiono w pozycji [3]. Poniżej przedstawiono adaptację tej metody do uczenia parametrów regulatora Takagi-Sugeno. Schemat struktury rozmyto-neuronowej realizującej uczenie ze wzmocnieniem przedstawiono na rys. 5.

Sieć uczenia ze wzmocnieniem zrealizowana na podstawie regulatora Takagi-Sugeno (w skrócie T.-S.) składa się z dwóch takich regulatorów. Jeden z nich pełni funkcję klasycznego regulatora, który na podstawie wektora zmiennych stanu i wiedzy w postaci rozmytych reguł wypracowuje wektor sterowań (tzw. wektor akcji). Wynik działania akcji na środowisko zewnętrzne jest następnie oceniany, a wynik w formie zewnętrznego sygnału wzmocnienia podawany jest do sieci uczenia ze wzmocnieniem, gdzie stanowi podstawę algorytmu uczenia. Drugi regulator T.-S. służący do predykcji zewnętrznego sygnału wzmocnienia (stąd też będzie dalej nazywany rozmytym predyktorem). Obydwa regulatory posiadają wspólne funkcje przynależności, natomiast bazy reguł i wartości sterowań są niezależne.

Celem uczenia ze wzmocnieniem będzie taka modyfikacja wartości sterowań c_{kn} regulatora akcji, która zapewni maksymalizację sygnału wzmocnienia, co można wyrazić następująco

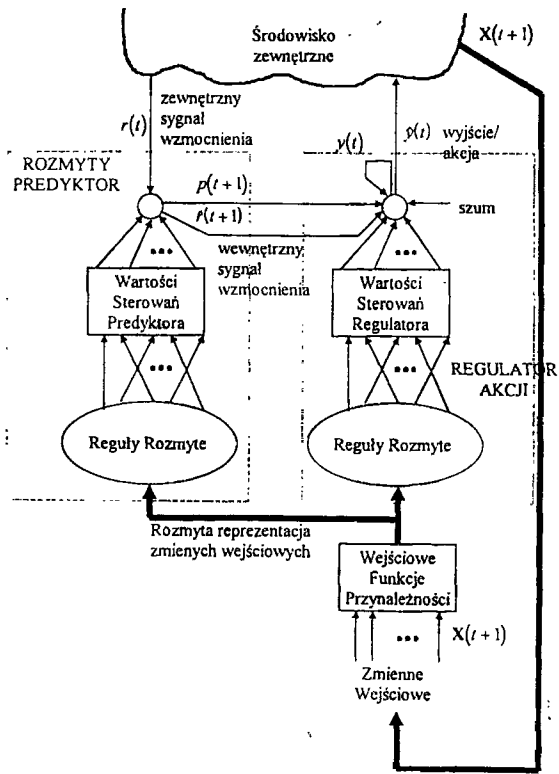
$$\Delta c_{kn} \propto \frac{dr}{dc_{kn}}. \quad (7)$$

Zmodyfikowany algorytm największego spadku (4) przyjmie więc postać

$$c_{kn}(t+1) = c_{kn}(t) + \eta \cdot \left(-\frac{dr}{dc_{kn}} \right), \quad (8)$$

gdzie

$$\frac{dr}{dc_{kn}} = \frac{dr}{dv_k} \cdot \frac{dv_k}{dc_{kn}}. \quad (9)$$



Rys. 5. Sieć uczenia ze wzmocnieniem zbudowana na podstawie regulatora Takagi-Sugeno

Rozumowanie, którego rezultatem było oszacowanie pochodnej $\frac{dr}{dv_k}$ wyrażeniem

$$\left[r(t) - p(t) \right] \left[\frac{\hat{v} - v}{\sigma} \right]_{(t-1)}, \text{ gdzie } \sigma(t) = \frac{1}{1 + e^{2p(t)}}, \text{ zaś } p(t) \text{ jest predykcją sygnału wzmocnienia}$$

(wyściem predyktora rozmytego) przedstawiono w pracy [3].

Ostatecznie po podstawieniu (9) do (8) i uwzględnieniu zależności (1) otrzymano zmodyfikowany dla potrzeb uczenia ze wzmocnieniem regulatora T.-S. algorytm największego

$$c_{kn}(t+1) = c_{kn}(t) + \eta_c \cdot [r(t) - p(t)] \left[\frac{\hat{v}_k - v_k}{\sigma} \right]_{(t-1)} \cdot \frac{\beta_n}{\sum_{n=1}^N \beta_n} \quad (10)$$

5.3. Predyktor rozmyty zrealizowany na podstawie regulatora Takagi-Sugeno

Jak już wspomniano wcześniej rolę rozmytego predyktora będzie również pełnił regulator T.-S. Problem predykcji i jego rozwiązanie metodą różnic czasowych prezentowano w pracy [3]. Algorytm uczenia rozmytego predyktora jest analogiczny do przedstawionego powyżej

algorytmu uczenia ze wzmacnieniem (10), w który sygnał błędu $[r(t) - p(t)] \left[\frac{\hat{y} - y}{\sigma} \right]_{t-1}$ został zastąpiony przez wewnętrzny sygnał wzmacnienia $\hat{r}(t)$ określony zależnością (11)

$$\hat{r}(t) = r(t) + \gamma p(t) - p(t-1), \quad 0 \leq \gamma < 1. \quad (11)$$


W wyniku podstawień otrzymano

$$c_{kn}^{(p)}(t+1) = c_{kn}^{(p)}(t) + \eta \cdot (r(t) + \gamma p(t) - p(t-1)) \cdot \frac{\beta_n}{\sum_{n=1}^N \beta_n} \quad (12)$$


gdzie $c_{kn}^{(p)}$ jest wartością sterowania rozmytego predyktora związaną z k -tym wyjściem i n -tą regułą.

6. WYNIKI EKSPERYMENTÓW

Program, napisany w języku C, generował sterowanie co 55ms. Komunikacja z robotem odbywała się za pośrednictwem łącza szeregowego. Początkowe wartości sterowań c_{ij}^k były małymi liczbami losowymi z przedziału $(0 \div 0.1)$. Eksperyment obejmował poszukiwanie ośmiu celów o współrzędnych $(7R, 7R)$, $(-7R, -7R)$, $(-7R, 0)$, $(-7R, 7R)$, $(0, -7R)$, $(7R, -7R)$, $(0, 7R)$ i $(7R, 0)$. Robot rozpoczynał poszukiwanie celu zawsze z punktu o współrzędnych $(0, 0)$, a kończył, gdy odległość od celu była mniejsza od promienia robota R . Trajektorie robota w trakcie uczenia przedstawiono na rys. 6. Szarymi kołami zaznaczono położenie punktów docelowych wraz z otoczeniem równym R .



Rys. 6. Trajektorie robota w trakcie uczenia ze wzmacnieniem



Rys. 7. Trajektorie robota realizującego zadanie poszukiwania celu z wykorzystaniem nauczonego zbioru reguł

z	Ψ	c'_{ij}	c''_{ij}
Near	Negative	-3,50	10,50
Near	Zero	11,33	15,22
Near	Positive	16,41	- 2,22
Far	Negative	-9,74	5,53
Far	Zero	13,64	14,45
Far	Positive	14,46	-1,78

Tabela 2. Tablica reguł realizująca zadanie poszukiwania celu otrzymana w procesie uczenia ze wzmocnieniem

W wyniku uczenia otrzymano wartości sterowań, które przedstawiono w tabeli 2. Jednostką prędkości jest *impuls / 10ms*, co odpowiada rzeczywistej prędkości *8mm / s*.

W celu sprawdzenia poprawności pracy nauczonego regulatora rozmytego przeprowadzono eksperymenty, których celem było osiągnięcie wspomnianych wcześniej punktów. Zadane punkty zostały osiągnięte (rys. 7).

VII. PODSUMOWANIE

Zastosowana metoda uczenia wzmocnionego pozwoliła na adaptacyjny dobór sterowań rozmytego regulatora zmodyfikowanego. Zalety tej metody uwidaczniają się w przypadku dużej liczby reguł, gdy intuicyjne ich sformułowanie staje się uciążliwe lub praktycznie niemożliwe.

Równoległe prace prowadzone na robocie Khepera doprowadziły do podobnych wniosków. Po przeprowadzeniu dodatkowych doświadczeń możliwym jest przeprowadzenie eksperymentów z doбором nastaw na zajęciach dydaktycznych.

Praca finansowana przez Komitet Badań Naukowych w ramach grantu nr 8 T11A 028 11.

LITERATURA

- [1] KLUSKA J., *Sterowanie z logiką rozmytą*, Zeszyty Naukowe Politechniki Rzeszowskiej, Seria Elektrotechnika, Zeszyt 12, Nr 104, Rzeszów 1992.
- [2] KLUSKA J., WIKTOROWICZ K., *Automatic generating of fuzzy control rules for a fuzzy logic controller using Matlab*, Conf. 12th International Conference on Systems Science, Wrocław 1995, pp. 434-443.
- [3] LIN C.T., *A neural fuzzy control system with structure and parameter learning*, Fuzzy Sets and Systems 70 (1995) 183-212
- [4] ZAJDEL R., *Układy logiki rozmytej i sieci neuronowych. Sprzęt i oprogramowanie - część I. Pomiary* Automatyka Kontrola, 8, 209 - 212, 1996.
- [5] ZAJDEL R., *Układy logiki rozmytej i sieci neuronowych. Sprzęt i oprogramowanie - część II. Pomiary* Automatyka Kontrola, 9, 237 - 240, 1996.
- [6] PŁOCHA R., WIKTOROWICZ K., *Realizacja zadania omijania przeszkód dla trójkołowego robota mobilnego*. Konferencja Naukowo-Techniczna Automatykacja - Nowości i Perspektywy (1998)