

# STEROWANIE NEURONOWO–ROZMYTE MOBILNYM ROBOTEM KOŁOWYM

Zenon HENDZEL\*, Magdalena MUSZYŃSKA\*

\*Katedra Mechaniki Stosowanej i Robotyki, Wydział Budowy Maszyn i Lotnictwa, Politechnika Rzeszowska, ul. Powstańców Warszawy 8, 35-959 Rzeszów

[zenhen@prz.edu.pl](mailto:zenhen@prz.edu.pl), [magdaw@prz.edu.pl](mailto:magdaw@prz.edu.pl)

**Streszczenie:** W niniejszej pracy do rozwiązania problemu sterowania ruchem mobilnego robota kołowego zastosowano inteligentny układ sterowania, rozumiany jako sterowanie hybrydowe łączące logikę rozmytą i sztuczne sieci neuronowe. Układ ten został zaprojektowany w taki sposób, aby na bieżąco modyfikować swoje właściwości przy zmieniających się warunkach pracy mobilnego robota. Badania symulacyjne zostały przeprowadzone dla przypadku kiedy wybrany punkt mobilnego robota przemieszcza się po trajektorii w kształcie pętli.

## 1. WPROWADZENIE

Rozwój technik dla autonomicznej nawigacji robota tworzy jeden z głównych trendów w aktualnych badaniach nad robotyką. Trend ten jest umotywowany występowaniem luki między dostępną technologią a nowymi wymaganiami. Z jednej strony roboty przemysłowe pozbawione są możliwości dostosowania się do danego środowiska i autonomii. Zwykle roboty te wykonują wcześniej zaprogramowany ciąg instrukcji działań w bardzo ograniczonym środowisku i nie są zdolne do pracy w nowym otoczeniu czy też wychodzeniu naprzeciw nowym sytuacjom. Z drugiej strony powstający rynek potrzebuje inteligentnych robotów do pracy w biurach, szpitalach, fabrykach. Roboty te mają możliwość pracy w niebezpiecznych lub trudno dostępnych obszarach. Wbrew imponującym postępom w dziedzinie autonomicznej robotyki w ostatnich latach pozostaje kilka problemów, które wymagają rozwiązań. Do problemów tych możemy zaliczyć uwzględnienie niedokładności modelowania. Niepewności te wynikają ze zmiennych warunków pracy przy realizacji różnych zadań przez mobilne roboty kołowe. Dlatego też, niezbędne jest opracowanie odpowiednich algorytmów sterowania w czasie rzeczywistym (Antonelli i inni, 2007; Hendzel i Wereszczak, 2008). W syntezie wcześniej wspomnianych algorytmów sterowania może być zastosowane między innymi podejście klasyczne bazujące na teorii układów o zmiennej strukturze (Slotine i Sastry, 1983). Wśród metod stosowanych do projektowania układów sterowania w warunkach niepewności bardzo dużym zainteresowaniem cieszą się techniki stosowane w obszarze sztucznej inteligencji – sieci neuronowe i układy z logiką rozmytą (Piegat, 1999; Rutkowski, 2005). Układy te stosowane są ze względu na możliwość uzyskania prostych ale odpornych rozwiązań, które obejmują szeroki zakres zmian parametrów obiektu. Ponadto układy te posiadają zdolność do aproksymacji dowolnych odwzorowań nieliniowych oraz w przypadku sieci neuronowych możliwość uczenia się i adaptacji (Piegat, 1999; Rutkowski, 2005). W niniejszej pracy został opracowany

inteligentny sterownik ruchu nadążnego bazujący na sieciach neuronowych i układach z logiką rozmytą zadaniem którego jest kompensacja nieliniowości i niedokładności modelowania mobilnego robota kołowego. Powstały układ hybrydowy nazywany jest układem neuronowo-rozmytym. Łączy on zarówno zalety sieci neuronowych i układów z logiką rozmytą. Pozostała część referatu jest zorganizowana następująco. W rozdziale drugim zawarte są dynamiczne równania ruchu mobilnego robota 2-kołowego. W rozdziale trzecim omówiono zastosowany układ hybrydowy i właściwości kompensatora neuronowo-rozmytego. Rozdział 4 zawiera wyniki testu numerycznego a rozdział 5 podsumowuje rezultaty przeprowadzonych badań.


## 2. OPIS RUCHU MOBILNEGO ROBOTA

Obiektem sterowania jest 2-kołowy mobilny robot, którego schemat pokazano na (Rys. 1) (Giergiel i inni, 2002). Dynamiczne równania ruchu 2-kołowego mobilnego robota można przedstawić w postaci następującego równania:

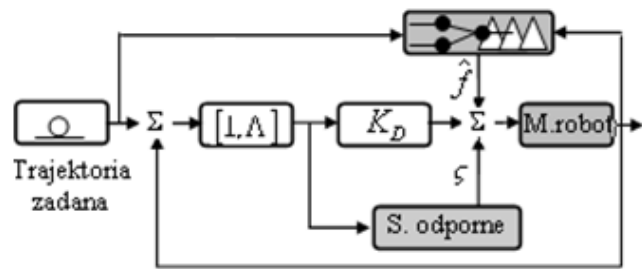
$$\begin{bmatrix} a_1 + a_2 + a_3 & a_1 - a_2 \\ a_1 - a_2 & a_1 + a_2 + a_3 \end{bmatrix} \begin{bmatrix} \ddot{\alpha}_1 \\ \ddot{\alpha}_2 \end{bmatrix} + \begin{bmatrix} 0 & 2a_4(\dot{\alpha}_2 - \dot{\alpha}_1) \\ -2a_4(\dot{\alpha}_2 - \dot{\alpha}_1) & 0 \end{bmatrix} \begin{bmatrix} \dot{\alpha}_1 \\ \dot{\alpha}_2 \end{bmatrix} + \begin{bmatrix} a_5 \operatorname{sgn} \dot{\alpha}_1 \\ a_6 \operatorname{sgn} \dot{\alpha}_2 \end{bmatrix} = \begin{bmatrix} M_1 \\ M_2 \end{bmatrix} \quad (1)$$

gdzie  $a_i$  to parametry wynikające z geometrii układu, rozkładu mas oraz oporów ruchu analizowanego układu a  $M_1$  i  $M_2$  to momenty napędzające koła, lub w zapisie wektorowo macierzowym w postaci równania (2):

$$M \ddot{\alpha} + C(\dot{\alpha}) \dot{\alpha} + F(\dot{\alpha}) = u, \quad (2)$$



Rys. 1. Schemat mobilnego robota Pioneer 2-DX



Rys. 2. Schemat układu sterowania

Dla zadanej trajektorii ruchu

$\alpha_d = [\alpha_1, \alpha_2]^T$ ,  $\dot{\alpha}_d = [\dot{\alpha}_1, \dot{\alpha}_2]^T$ ,  $\ddot{\alpha}_d = [\ddot{\alpha}_1, \ddot{\alpha}_2]^T$  definiujemy błąd nadążania

$$e = \alpha_d - \alpha, \quad (3)$$

oraz uogólniony błąd nadążania w postaci:

$$s = \dot{e} + \Lambda e, \quad (4)$$

gdzie  $\Lambda$  to macierz projektowa odpowiedniego wymiaru, diagonalna dodatnio określona. Różniczkując równanie (4) oraz uwzględniając dynamiczne równania mobilnego robota (2), otrzymujemy opis układu sterowania w funkcji uogólnionego błędu  $s$

$$M\dot{s} = -C(\dot{\alpha})s + f(x) - u, \quad (5)$$

a nieliniowa funkcja  $f(x)$  dana jest zależnością

$$f(x) = M\dot{v} + C(\dot{\alpha})v + F(\dot{\alpha}) \quad (6)$$

gdzie  $v = \dot{\alpha}_d + \Lambda e$ ,  $\dot{v} = \ddot{\alpha}_d + \Lambda \dot{e}$ .

Ogólna postać sygnału sterowania z uwzględnieniem kompensacji nieliniowości modelu mobilnego robota kołowego jest następująca (Giergiel i inni, 2002):

$$u = \hat{f} + K_D s - \zeta, \quad (7)$$

gdzie  $\zeta$  to sterowanie odporne,  $\hat{f}$  to funkcja aproksymująca nieliniową zależność (6) (sterowanie kompensacyjne), natomiast

$$K_D s = K_D \Lambda e + K_D \dot{e}, \quad (8)$$

to równanie regulatora PD ze współczynnikami wzmocnienia regulatora D,  $K_D$  oraz regulatora proporcjonalnego

$K_D \Lambda$ .

W układzie sterowania jak pokazano na (Rys.2) możemy wyróżnić takie elementy jak mobilny robot, regulator PD, sterowanie odporne oraz kompensator neuronowo-rozmyty generujący sygnał  $\hat{f}$ .

Rozpisując zależność (6) otrzymamy:

$$\begin{bmatrix} f_1 \\ f_2 \end{bmatrix} = \begin{bmatrix} (\dot{v}_1 + \dot{v}_2)a_1 + (\dot{v}_1 - \dot{v}_2)a_2 + \dot{v}_1 a_3 + \\ 2(\ddot{\alpha}_2 - \ddot{\alpha}_1)v_2 a_4 + a_5 \operatorname{sgn} \dot{\alpha}_1 \\ (\dot{v}_1 + \dot{v}_2)a_1 + (\dot{v}_2 - \dot{v}_1)a_2 + \dot{v}_2 a_3 + \\ 2(\ddot{\alpha}_2 - \ddot{\alpha}_1)v_1 a_4 + a_6 \operatorname{sgn} \dot{\alpha}_2 \end{bmatrix} \quad (9)$$

Zgodnie z twierdzeniem mówiącym o dokładności aproksymacji nieliniowej funkcji modelem neuronowo-rozmytym (Piegat, 1999), ze wzrostem stopnia złożoności modelu (ilość reguł, liczba zbiorów rozmytych) rośnie jego możliwość do dokładnego odwzorowania. Jakkolwiek, przy większej ilości wejść modelu neuronowo-rozmytego pojawia się problem eksplozji rozwiązań. Aby uniknąć tego typu zjawisk wprowadzmy strukturalne sterowanie neuronowo-rozmyte poprzez zastąpienie modelu złożonego, modelami prostymi. Takie podejście upraszcza problem projektowania, wprowadza nową strukturę sterowania neuronowo-rozmytego i przyspiesza proces obliczeniowy. Elementy wektora sterowania kompensującego nieliniowości mobilnego robota, można zapisać jako:

$$\begin{aligned} f_{nr1} &= g_1 + g_2 + g_3 \\ f_{nr2} &= g_4 + g_5 + g_6, \end{aligned} \quad (10)$$

gdzie składowe elementów w których zastosowano aproksymację oporów ruchu funkcją tangens hiperboliczny, wynoszą

$$\begin{aligned} g_1 &= (\dot{v}_1 + \dot{v}_2)a_1 + (\dot{v}_1 - \dot{v}_2)a_2 + \dot{v}_1 a_3 \\ g_2 &= 2\ddot{\alpha}_2 v_2 a_4 \\ g_3 &= -2\ddot{\alpha}_1 v_2 a_4 + a_5 \frac{(1 - e^{-\beta \dot{\alpha}_1})}{(1 + e^{-\beta \dot{\alpha}_1})} \\ g_4 &= (\dot{v}_1 + \dot{v}_2)a_1 + (\dot{v}_2 - \dot{v}_1)a_2 + \dot{v}_2 a_3 \\ g_5 &= 2\ddot{\alpha}_1 v_1 a_4 \\ g_6 &= -2\ddot{\alpha}_2 v_1 a_4 + a_6 \frac{(1 - e^{-\beta \dot{\alpha}_2})}{(1 + e^{-\beta \dot{\alpha}_2})}, \end{aligned} \quad (11)$$

$\beta = \text{const}$ .

### 3. NEURONOWO - ROZMYTY KOMPENSATOR NIELINIOWOŚCI

W niniejszej pracy do aproksymacji nieliniowości mobilnego robota zastosowano układ neuronowo-rozmyty. Układy te są pewnym podzbiorem układów z logiką rozmytą. Uczniemu w tym układzie podlegają parametry konkluzji i przesłanek bazy reguł modelu Sugeno. Do aproksymacji nieliniowości zastosowano model rozmyty w postaci bazy reguł:

$$R_j : IF (x_1 = A_{j1}) AND (x_2 = B_{j1}) THEN (g = w_j) \quad (12)$$

$j = 1, 2, \dots, N$

gdzie  $x_1, x_2$  to sygnały wejściowe,  $A_{j1}$  i  $B_{j1}$  to zbiory rozmyte które reprezentowane są przez funkcje Gaussa, uczone są

parametry tych zbiorów tzn. szerokość i środek,  $w_j$  to konkluzje bazy reguł. Model rozmyty z uwzględnieniem bazy reguł (12) zapiszemy w postaci równania (13):

$$g_k = \sum_{j=1}^N w_{kj} \phi_j, k = 1, 2, \dots, 6 \quad (13)$$

Dalsze rozważania przeprowadzimy dla dowolnej funkcji  $g_k$  występujących w zależności (10) opuszczając indeks  $k$ , otrzymamy:

$$g = \sum_{j=1}^N w_j \phi_j \quad (14)$$

lub

$$g = W^T \phi \quad (15)$$

W zależności (14) i (15) stopień spełnienia przesłanki danej reguły przyjęto w postaci:

$$\phi_j = \mu_{A_j}(x_1) \cdot \mu_{B_j}(x_2), j = 1, 2, \dots, N \quad (16)$$

gdzie  $\mu_{A_j}(x_1)$  i  $\mu_{B_j}(x_2)$  to zbiory rozmyte opisane poniższą funkcją Gaussa:

$$\mu_{A_{ji}}(x_i) = e^{-r_{ji}^2(x_i - c_{ji})^2} \quad (17)$$

$r_{ji}$  oraz  $c_{ji}$  to odpowiednio odwrotność szerokości i środek funkcji Gaussa. Uwzględniając (17) stopień spełnienia przesłanki danej reguły (16) zapiszemy jako:

$$\phi_j = e^{-r_{j1}^2(x_1 - c_{j1})^2 - r_{j2}^2(x_2 - c_{j2})^2} \quad (18)$$

Zapiszmy część kompensującą algorytm sterowania w postaci:

$$f = \begin{bmatrix} f_{nr1} \\ f_{nr2} \end{bmatrix} = \begin{bmatrix} W^{(1)T} \cdot \phi^{(1)} + W^{(2)T} \cdot \phi^{(2)} + \\ + W^{(3)T} \cdot \phi^{(3)} \\ W^{(4)T} \cdot \phi^{(4)} + W^{(5)T} \cdot \phi^{(5)} + \\ + W^{(6)T} \cdot \phi^{(6)} \end{bmatrix} \quad (19)$$

gdzie

$$W^{(1)T} \cdot \phi^{(1)} = \begin{bmatrix} w_{11}^{(1)} & w_{12}^{(1)} & \dots & w_{19}^{(1)} \end{bmatrix} \begin{bmatrix} \phi_1^{(1)} \\ \phi_2^{(1)} \\ \vdots \\ \phi_9^{(1)} \end{bmatrix} \quad (20)$$

a pozostałe wyrażenia określono podobnie. W zależności (20)  $W^{(1)T}$  to wektor konkluzji bazy reguł a  $\phi^{(1)}$  to wektor oceny przesłanek w bazie reguł modelu neuronowo-rozmytego aproksymującego funkcje  $g_i$ . Biorąc pod uwagę powyższe oznaczenia aproksymację nieliniowej funkcji modelu neuronowo-rozmytego zapiszemy jako:

$$f = W_{nr} \cdot \phi_{nr} = \begin{bmatrix} W^{(1)T} & W^{(2)T} & W^{(3)T} & 0 & 0 & 0 \\ 0 & 0 & 0 & W^{(4)T} & W^{(5)T} & W^{(6)T} \end{bmatrix} \begin{bmatrix} \phi^{(1)} \\ \phi^{(2)} \\ \vdots \\ \phi^{(6)} \end{bmatrix} \quad (21)$$

Przyjmujemy oznaczenia:

$$\tilde{W}_{nr} = W_{nr} - \hat{W}_{nr} \quad (22)$$

$$\tilde{\phi}_{nr} = \phi_{nr} - \hat{\phi}_{nr} \quad (23)$$

gdzie  $\hat{W}_{nr}, \hat{\phi}_{nr}$  to estymaty odpowiednio konkluzji bazy reguł i oceny przesłanek. Zależność (23) wynika z faktu wprowadzenia adaptacji parametrów ( $r_{ji}$ ) i ( $c_{ji}$ ) funkcji Gaussa. Estymacja tych parametrów zbiorów rozmytych jest złożona ze względu na występowanie ich w zależnościach nieliniowych co znacznie utrudnia syntezę neuronowo-rozmytego algorytmu sterowania tym robotem. Jedną z metod rozwiązania tego problemu jest linearyzacja wektora  $\tilde{\phi}_{nr}$  opisanego zależnością (23), która prowadzi do formy liniowej ze względu na estymowane parametry, co jest warunkiem implementacji tego rozwiązania w czasie rzeczywistym. Można ją zapisać w postaci równania (24)

$$\tilde{\phi}_{nr} = A^T \tilde{r}_{ji} + B^T \tilde{c}_{ji} + h \quad (24)$$

$h$  to niedokładności wynikające z linearyzacji funkcji (18) w celu uzyskania liniowej formy estymowanej funkcji Gaussa. Będą one kompensowane z zastosowaniem algorytmu odpornego  $\varsigma$ ,  $A$  i  $B$  to macierze wynikające z rozpisania równania (23) w szereg Taylora. W wyniku tak przeprowadzonej linearyzacji równanie układu zamkniętego zapiszemy jako:

$$M\dot{s} = -[K_D + C(\dot{\alpha})]s + \tilde{W}_{nr}^T \begin{bmatrix} \hat{\phi}_{nr} - A^T \hat{r}_{ji} + \\ -B^T \hat{c}_{ji} \end{bmatrix} + \tilde{W}_{nr}^T (A^T \tilde{r}_{ji} + B^T \tilde{c}_{ji}) + d_f + \varsigma \quad (25)$$

gdzie

$$d_f = \tilde{W}_{nr}^T [A^T r_{ji} + B^T c_{ji}] + W_{nr}^T h + \varepsilon + \tau_d \quad (26)$$

Natomiast  $\varepsilon$  to błąd aproksymujący nieliniową funkcje  $g_i$  przez model neuronowo-rozmyty. Do uczenia środków, szerokości funkcji Gaussa oraz konkluzji bazy reguł przyjęto zależności które zostały wyprowadzone na podstawie stabilności Lapunowa, a mianowicie prawo uczenia:

$$\dot{\hat{W}}_{nr} = F_w \hat{\phi}_{nr} s^T - F_w (A^T \hat{r}_{ji} + B^T \hat{c}_{ji}) s^T - F_w \cdot \|s\| \hat{W}_{nr} \quad (27)$$

$$\dot{\hat{r}}_{ji}^k = F_r A \hat{W}_{nr} s - F_r \|s\| \hat{r}_{ji} \quad (28)$$

$$\dot{\hat{c}}_{ji}^k = F_c B \hat{W}_{nr} s - F_c \|s\| \hat{c}_{ji} \quad (29)$$

gdzie  $F_w, F_r, F_c$  to macierze współczynników wzmocnień procesu uczenia. Sterowanie odporne przyjęto w postaci równania (30):

$$\varsigma = -\frac{s}{\|s\|} K_D^T Y \quad (30)$$

Wektory  $K_D$  i  $Y$  wynikają z unormowania wektora  $d_f$  (26) i mają postać:

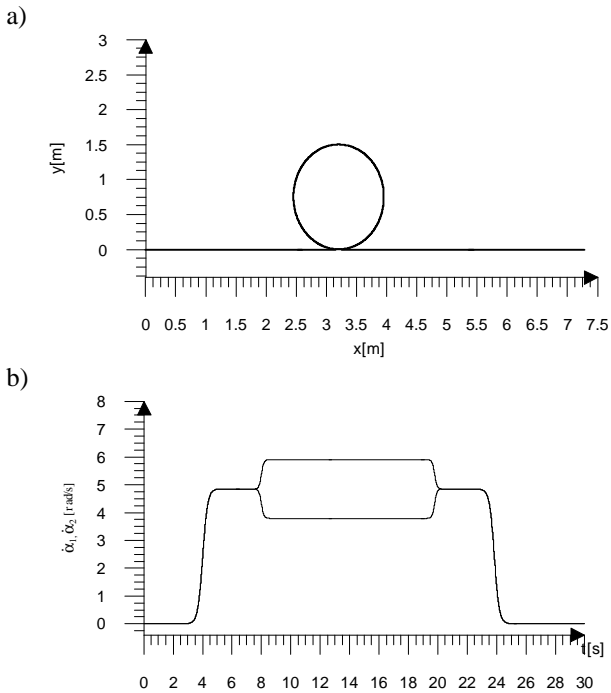
$$K_D = [d_1, d_2, d_3, d_4]^T \quad (31)$$

$$Y = [1, \|\hat{w}\|, \|\hat{r}\|, \|\hat{c}\|] \quad (32)$$

gdzie elementy wektora  $K_D$  to stałe wartości.


#### 4. WYNIKI TESTU NUMERYCZNEGO

Na podstawie rozważań teoretycznych przeprowadzono analizę numeryczną analizowanych rozwiązań. Badania zostały przeprowadzone w pakiecie Matlab/Simulink. Zadana trajektorię do neuronowo-rozmytego sterowania ruchem nadążnym mobilnego robota przyjęto w kształcie pętli pokazanej na (Rys. 3a), natomiast na (Rys. 3b) przedstawiono zadane przebiegi prędkości kątowych kół robota.




**Rys. 3.** a) Zadana trajektoria ruchu punktu, b) prędkości kątowe kół napędzających


Symulację zaproponowanych rozwiązań przeprowadzono dla następujących danych  $V_A=0.4$ [m/s],  $K_D=\text{diag}[3,3]$ ,  $\Lambda=\text{diag}[2,2]$ . Parametry  $\Lambda$  i  $K_D$  zostały tak dobrane aby zapewnić małą wrażliwość na zmiany parametrów układu oraz inne zakłócenia, a jednocześnie umożliwić realizację sterowania na obiekcie rzeczywistym.




b)




c)



d)

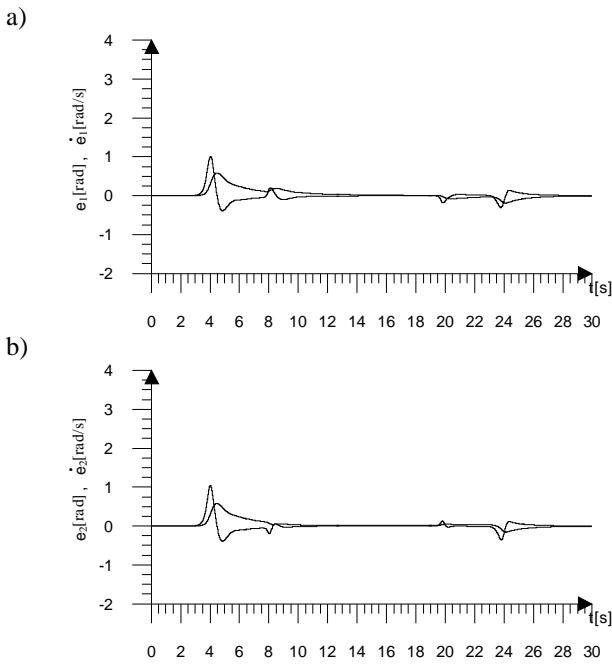


e)

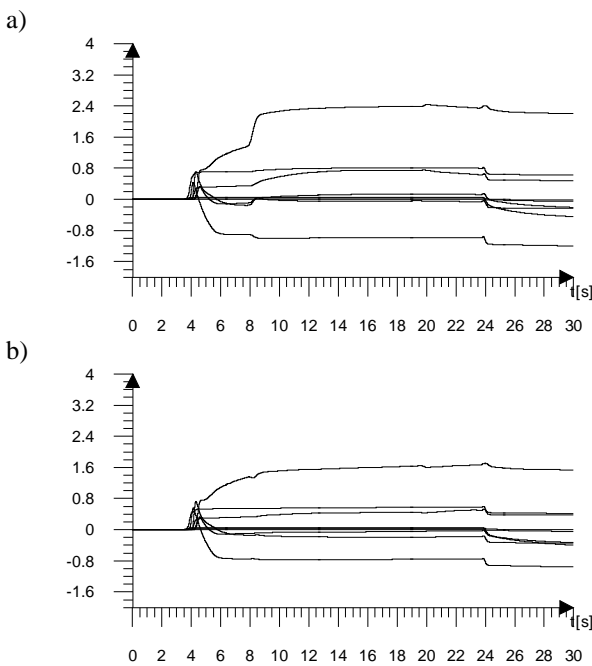


**Rys. 4.** Wyniki symulacji ruchu punktu mobilnego robota, a) sterowanie całkowite b) sterowanie kompensacyjne c) sterowanie PD d) zestawienie sterowanie kompensacyjnego i PD e) sterowanie odporne

Stosując algorytm sterowania (7) i algorytm uczenia zarówno konkluzji (27) jak i przesłanki bazy reguł (28,29), otrzymano wartości momentów kół napędzających 1 i 2, które pokazano na (Rys. 4a). Na (Rys. 4d) zestawiono sterowanie kompensacyjne i sterowanie za pomocą regulatora PD.




Rys. 5. Przebieg błędów nadążania oraz błędów prędkości nadążania dla a) koła 1 i b) koła 2




Rys. 6. Przebieg wybranych wag konkluzji bazy reguł dla funkcji a)  $g_2$  i b)  $g_5$

Jak wynika z przebiegów przedstawionych na Rys. 4 na początku ruchu realizowane jest sterowanie PD, w miarę uczenia sterowanie konwencjonalne zostaje zastąpione sterowaniem kompensacyjnym. Przedstawione sygnały błędów nadążania oraz prędkości nadążania na Rys. 5 wskazują iż największe błędy można zauważyć w okresie rozruchu i hamowania. Błędy podczas rozruchu wynikają z faktu, iż dopiero zaczynał się proces adaptacji parametrów obiektu. Natomiast występowanie błędów w okresie hamowania, wynika ze zmieniającej się trajektorii zadanej. Błąd ten jest szybko kompensowany przez algorytm sterowania neuronowo-rozmytego. Błędy te są zbieżne do zera. Otrzy-

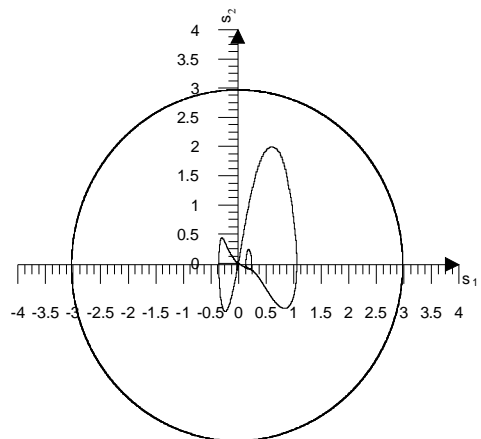
mane błędy sterowania można zmniejszyć przez odpowiedni dobór macierzy  $K_D$  oraz założenie niezerowych warunków początkowych w procesie uczenia. Na Rys. 6 zamieszczone wybrane oceny wag sieci konkluzji bazy reguł. Oceny te dążą do stałych wartości.



Rys. 7. Przebieg uczenia szerokości funkcji Gaussa znajdujących się w przesłankach bazy reguł układu neuronowo-rozmytego



Rys. 8. Przebieg uczenia środków funkcji Gaussa znajdujących się w przesłankach bazy reguł układu neuronowo-rozmytego



Rys. 9. Płaszczyzna uogólnionych błędów nadążania

Na Rys. 7 i 8 przedstawiono przebiegi uczenia parametrów przesłanki bazy reguł układu neuronowo-rozmytego. Uczone były zarówno szerokości jak i środki funkcji Gaussa.

Na początku procesu uczenia założono równomierny rozkład zbiorów rozmytych. Z przebiegów tych zauważalna jest zmiana szerokości i środków podczas realizacji ruchu. Na Rys.9 zamieszczono przebiegi uogólnionych błędów nadążania z którego wynika ich ograniczoność. Z przepro-

wadzonej symulacji widać iż testowany algorytm sterowania neuronowo-rozmytego (7) zapewnia stabilność badanego układu sterowania.

## 5. WNIOSKI

W referacie tym przeanalizowano tematykę związaną z adaptacją konkluzji i przesłanki bazy reguł układu neuronowo-rozmytego, zastosowanego do aproksymacji nieliniowości występujących w sterowaniu ruchem nadążnym mobilnego robota kołowego. Zastosowany inteligentny układ sterowania łączył w sobie zalety sieci neuronowych i układów z logiką rozmytą. Oba podejścia doskonale nadają się do rozwiązywania problemów z którymi tradycyjne układy regulacji nie najlepiej sobie radzą. Uczzone były konkluzje bazy reguł oraz parametry przesłanki czyli szerokości i środki funkcji Gaussa. Na początku procesu uczenia założone były zerowe wartości początkowe wag konkluzji oraz równomierny podział przestrzeni rozważań. Dla każdej zmiennej wejściowej założono 3 zbiory rozmyte. Z przeprowadzonych badań wynika iż układy te mogą stanowić jeden ze sposobów aproksymacji nieliniowych odwzorowań. Proces uczenia był krótki a zastosowane podejście umożliwiło odwzorowanie nieliniowości robota z dużą dokładnością. Błędy nadążania są zbieżne do zera. Przeprowadzone badania są próbą zastosowania w mechanice nowoczesnych technologii informatycznych rozumianych jako sterowanie w czasie rzeczywistym, uwzględniające parametryczne i nieparametryczne niedokładności modelowania nieliniowego obiektu. Uzyskane wyniki potwierdzają poprawność przyjętej metody kompensacji nieliniowości.

## LITERATURA

1. **Antonelli G., Chiaverini S., Fusco G.** (2007), A Fuzzy-Logic-Based Approach for Mobile Robot Path Tracking, *IEEE Transaction on Fuzzy Systems*, Vol. 15, No 2.
2. **Giergiel M. J., Hendzel Z., Żylski W.** (2002), *Modelowanie i sterowanie mobilnych robotów kołowych*, PWN, Warszawa.
3. **Hendzel Z., Wereszczak M.** (2008), *Rozmyto-neuronowy algorytm sterowania mobilnym robotem kołowym*, Oficyna Wydawnicza Politechniki Warszawskiej, Prace Naukowe, Elektronika z.166, Warszawa, 463-472.
4. **Piegat A.** (1999), *Modelowanie i sterowanie rozmyte*, Akademicka Oficyna Wydawnicza EXIT, Warszawa.
5. **Rutkowski L.** (2005), *Metody i techniki sztucznej inteligencji*, Wydawnictwo Naukowe PWN, Warszawa.
6. **Slotine J.J., Sastry S.S.** (1983), Tracking control of nonlinear systems using sliding surfaces, with application to robot manipulators, *International Journal of Control*, Vol. 38, 465.

### A NEURO-FUZZY CONTROL OF A WHEELED MOBILE ROBOT

**Abstract:** This work analyses neuro-fuzzy algorithm adaptation conclusions and premise rule base, applied to approximation nonlinearity wheeled mobile robot. Computer simulation proposed solution was realized in emulator mobile robot.