

Adaptacyjny regulator neuronowo-rozmyty z rekurencjami i warstwą tranzycji Petriego w sterowaniu napędem elektrycznym

Streszczenie. Celem artykułu jest przeprowadzenie analizy możliwości wykorzystania Warstwy Tranzycji Petriego w adaptacyjnych regulatorach neuronowo-rozmytych z rekurencjami zwiększającymi wymiar bazy reguł regulatora. Zastosowanie rekurencji prowadzi do zmiany funkcji sterującej regulatora, co przy odpowiednim doborze rekurencji oraz parametrów regulatora prowadzi do poprawy wskaźników jakości sterowania. Niestety w przypadku regulatorów N-F z rekurencjami od wyjścia do wejścia lub innymi rozwiązaniami powodującymi zwiększenie liczby wejść regulatora, a tym samym wymiaru bazy reguł znacząco wzrasta złożoność obliczeniowa rozważanych algorytmów. Zastosowanie WTP pozwala na obniżenie kosztu numerycznego algorytmu. Jednoczesne zastosowanie zarówno rekurencji jak i WTP pozwala na jednoczesną poprawę wskaźników jakości sterowania bez zwiększania, a nawet przy zmniejszeniu kosztu numerycznego algorytmu. Rozważania teoretyczne zostały poparte badaniami symulacyjnymi jak i eksperymentalnymi. Zaproponowano także metodologię doboru nastaw regulatora.

Abstract This article aims to analyze the possibility of using Petri Transition Layer in the adaptive neuro-fuzzy controllers with recursions increasing number of controllers rules. The use of recursion leads to a change of control function, and an appropriate selection of recursion and controller parameters leads to improved control quality indicators. Unfortunately, in the case of NF controllers with output to input recursion or other solutions that cause an increase in the number of controller inputs, the dimension of the controllers rules base significantly increases the computational complexity of the algorithm. At the same time the use of PTL reduces the numerical cost of the algorithm. Simultaneous use of both recursion and PTL enables simultaneous improvements in quality control without increasing, and even while reducing the cost of numerical algorithm. Theoretical considerations have been supported by studies and experimental simulation. Also methodology of tuning of controller parameters was proposed. (**Adaptive neuro-fuzzy regulator with Recursions and Petri Transition layer in electric drive control**)

Słowa kluczowe: warstwa Petriego, neuronowo-rozmyty, regulator adaptacyjny, złożoność numeryczna, rekurencje

Keywords: Petri layer, neuro-fuzzy, adaptive controller, numerical complexity, recursion

Wstęp

Obecnie, w czasach gdy niemalże wszystkie procesy produkcyjne odbywają się z użyciem specjalizowanych linii procesowych nauka skupia się na tworzeniu coraz to dokładniejszych opisów obiektów tak aby skomplikowane procesy mogły się odbywać z możliwie wysoką dokładnością a produkt końcowy możliwie dokładnie odpowiadał projektowi. Na odpowiednio wysokim poziomie dokładności, po uwzględnieniu zjawisk rzeczywistych [1], [2], okazuje się, iż większość, jeżeli nie wszystkie obiekty są obiektami nieliniowymi [3].

Chęć poprawy jakości sterowania tymi procesami [4], czyli odtwarzania zadanych trajektorii przez maszyny wymaga tworzenia nieliniowych układów sterowania. Niniejszy artykuł ma na celu zaprezentowanie oraz opisanie regulatora neuronowo-rozmytego wykorzystującego 4 zmienne wejściowe oraz algorytm adaptacji współczynników wagowych w celu możliwie dobrego oraz szybkiego sterowania procesem nieliniowym.

Wykorzystany regulator jako sygnały wejściowe używa błędu śledzenia trajektorii zadanej, jego całki oraz pochodnej (PID) [2] a także sygnału wyjściowego regulatora (rekurencja) [5], [6]. Oczywiście z łatwością można by zastosować dowolne inne zmienne wejściowe, zgodnie z życzeniem projektanta. Z uwagi na wysoki rząd regulatora, a co za tym idzie znaczną złożoność numeryczną algorytmu wykorzystana została dodatkowo Warstwa Tranzycji Petriego (WTP) [7], [8] pozwalająca na istotne ograniczenie liczby operacji matematycznych koniecznych do wyznaczenia wartości sterowania w każdej iteracji.

Artykuł opisuje w pierwszej kolejności obiekt badawczy jakim jest zespół napędowy z silnikami prądu stałego z połączeniem sprzężystym, co więcej model ten uwzględnia współczynnik sprężystości oraz tłumienie połączenia sprzężystego pomiędzy napędem a obciążeniem [7], a także tarcie występujące w tym obiekcie. Następnie opisany został rozważany adaptacyjny regulator neuronowo-rozmyty. Oprócz opisu funkcjonalności każdej z warstw zaproponowana została metodologia doboru parametrów regulatora. W części końcowej zaprezentowane zostały

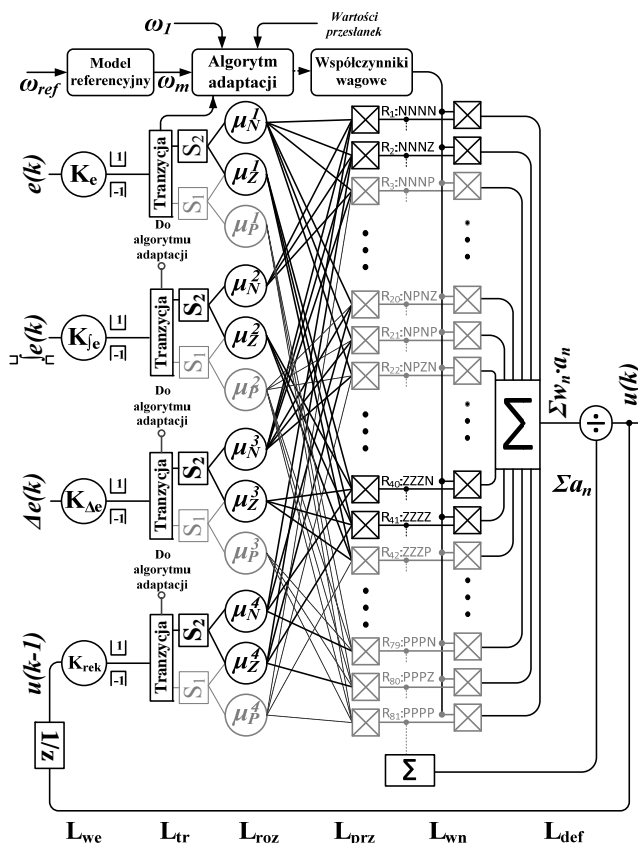
wybrane wyniki badań symulacyjnych. Analiza działania regulatora została przeprowadzona zarówno pod względem jakości śledzenia trajektorii zadanej jak i złożoności numerycznej zaproponowanego algorytmu w zależności od liczby wejść oraz liczby reguł przyporządkowanej każdemu z wejść.

Obiekt badawczy

Na potrzeby badań symulacyjnych w pakiecie Matlab-Simulink przygotowany został układ symulacyjny. Model uwzględnia moment bezwładności napędzającego silnika elektrycznego J_1 oraz obciążającego J_2 , część mechaniczną uwzględnia także tarcie wiskotyczne oraz Coulombowskie. Element sprężysty zamodelowano z użyciem dwóch jego parametrów, stałej sprężystości (K_s) oraz współczynnika tłumienia (D). Pomiar prędkości ω_1 odbywa się za pomocą enkodera o wzmacnieniu I oraz czasie opóźnienia różnym od zera. Sygnałami wejściowymi dla części mechanicznej układu są moment obciążenia (M_G) oraz napędzający moment elektromagnetyczny (M_e). W części elektrycznej uwzględniona została inercja oraz wzmacnienie obwodu elektromagnetycznego (K_b , T_e), założony został stały strumień wzbudzenia ($\psi_f = const$) natomiast pomiar prądu odbywa się za pomocą amperomierza o niezerowej inercji. Przekształtnik tyrystorowy również został uwzględniony w postaci bloku inercyjnego. W wewnętrznej pętli regulacji zastosowano klasyczny regulator prądu typu PI. W pętli nadrzędnej, regulacji prędkości, zastosowany został proponowany adaptacyjny regulator neuronowo-rozmyty z rekurencjami oraz warstwą tranzycji. Model matematyczny układu został przedstawiony między innymi w [9], [10].

Adaptacyjny Regulator Neuronowo-Rozmyty

Schemat rozważanego regulatora rozmytego o czterech zmiennych wejściowych zaprezentowano na rys. 1. Jako sygnały wejściowe zastosowano uchyb położenia ($e(t)$), jego pochodną ($\Delta e(t)$) i całkę ($\int e(t)$) [2], a także sprzężenie od sygnału wyjściowego regulatora. Neuronowo rozmyty system wnioskowania składa się z 6 warstw [7], których funkcje opisano poniżej:



Rys.1. Schemat regulatora

L_{we} : W warstwie wejściowej następuje skalowanie oraz ograniczanie sygnałów wejściowych, tak aby rozpatrywana przestrzeń każdej ze zmiennych została znormalizowana do zakresu ± 1 jednocześnie obejmując cały oczekiwany zakres wartości danej zmiennej.

$$(1) \quad L_{we_out} = \max[\min[(K_n \cdot in_n), 1], -1]$$

gdzie $n = [e(k), \Delta e(k), \int e(k), u(k-1)]$.

L_{tr} : W warstwie tranzycji następuje identyfikacja części zakresu zmiennej w jakim znajduje się ona w aktualnej iteracji algorytmu [7].

Wprowadzenie warstwy tranzycji pozwalającej na wybór odpowiednich funkcji przynależności, a dalej reguł na podstawie zidentyfikowanego obszaru przestrzeni zmiennych, w jakiej dana zmienna się obecnie znajduje. W niniejszym przypadku aktywnymi pozostają jedynie dwie funkcje przynależności dla każdego z wejść. Adaptowane są jedynie współczynniki wagowe odpowiadające regułom, których przesłanki są niezerowe. Podyktowane jest to chęcią zmniejszenia złożoności numerycznej algorytmu regulatora o dużej liczbie reguł.

Ponieważ tylko dwie funkcje są aktywne, dla przypadku o czterech wejściach i trzech funkcjach przynależności na każde z wejść, jedynie 2^4 zamiast 3^4 reguł jest rozważanych w każdym kroku. Zwiększenie liczby zbiorów do l_r , oraz liczby wejść do l_w , skutkuje wyznaczeniem 2^{l_w} zamiast $l_r^{l_w}$ reguł i adaptację takiej samej liczby współczynników wagowych.

Funkcje gaussowskie posiadają nieskończony nośnik, co oznacza, że dla dowolnej wartości wejściowej, każda z nich jest spełniona w niezerowym stopniu. Zastosowanie warstwy Petriego powoduje uwzględnienie tylko najbardziej aktywowanych sygnałów. W przypadku dużej liczby wejściowych zbiorów rozmytych okno aktywacji można rozszerzyć do większej liczby funkcji wejściowych przez

odpowiedni dobór parametrów warstwy tranzycji [9]. Oznacza to poszerzenie wielkości aktywnego obszaru sterowania, a tym samym adaptację konkluzji z nim związanej.

L_{roz}: W warstwie rozmywania zgodnie ze wzorem (2) następuje wyznaczenie wartości funkcji przynależności dla aktualnych wartości wejściowych. Wykorzystane zostały gaussowskie funkcje przynależności równomiernie rozłożone na przestrzeni rozważań każdej zmiennej. i – numer wejścia, j – numer l typu reguły zidentyfikowanej za pomocą warstwy tranzycji, n – liczba wejść, $Tr1$, $Tr2$ – funkcje przynależności odpowiadające sektorowi zidentyfikowanemu przez warstwę tranzycji.

$$(2) \quad [L_{roz_out}] = \left[\exp \left(- \left(\frac{(L_{roz_in}^i - \mu_j^i)^2}{2 \cdot (\sigma_j^i)^2} \right) \right) \right]_{\substack{i=1 \dots n \\ j=Tr1, Tr2}}$$

L_{prz} : W warstwie przesłanek następuje wyznaczenie poziomów przesłanek poszczególnych reguł. W pracy użyto jednej z popularniejszych t -norm typu *prod.* Baza reguł składa się z wyrażen typu [12]:

R_n : JEŻELI $e(k)$ JEST $\mu_{1j1}(e(k))$ I $e(k)$ JEST $\mu_{2j2}(e(k))$
I $\Delta e(k)$ JEST $\mu_{3j3}(\Delta e(k))$ I $u(k-1)$ JEST $\mu_{4j4}(u(k-1))$
TO $a_n = f_n(\mu_{1j1}, \mu_{2j2}, \mu_{3j3}, \mu_{4j4})$

$$(3) \quad [L_{reg_out}] = \left[\prod_{\substack{i=1 \dots n \\ j=Tr1, Tr2}} \mu_{ij} \right]$$

L_{wn} : W warstwie wnioskowania wyznaczone są wartości wyjściowe poszczególnych reguł. Każdy z sygnałów poziomu aktywacji przesłanki reguły mnożony jest przez odpowiadający mu współczynnik wagowy.

$$(4) \quad [L_{wn_out}] = \left[L_{wn_in}^i \cdot w_j^i \right]_{\substack{i=1 \dots n \\ j=Tr1, Tr2}}$$

L_{def} : W warstwie defuzyfikacji wyznaczana jest wartość wyjściowa sytemu rozmytego. W niniejszym przypadku użyto klasycznego algorytmu defuzyfikacji singletonami opisanego wzorem (5).

$$(5) \quad u(k) = \frac{\sum_{n=1}^m w_j^i \cdot a_j^i}{\sum_{n=1}^m a_j^i}$$

Algorytm adaptacji

Wartość poszczególnych współczynników wagowych w każdej iteracji opisana jest równaniem (6).

$$(6) \quad w_j^i(k+1) = w_j^i(k) + L_{wn_in}^i(k) \cdot [k_{em} e_m(k) + k_{\Delta m} \Delta e_m(k)]$$

W każdej iteracji algorytmu każdy z adaptowanych współczynników wagowych zmieniany jest o wartość zależną od aktualnego błędu odtwarzania modelu. Adaptowane są jedynie te wagi, które odpowiadają aktywnym regułom. Należy pamiętać o konieczności ograniczenia wartości maksymalnych współczynników wagowych i/lub o uwzględnieniu możliwości ograniczenia wyjścia, w takim wypadku możliwym rozwiązaniem jest zatrzymanie procesu adaptacji. Wagi powinny być ograniczone w taki sposób, aby ich wartości maksymalne

odpowiadały maksymalnemu pożądanemu ograniczeniu wartości wyjściowej regulatora, tu $\max(w_j^i) = \mathcal{F}3$. W przypadku takiego ograniczenia maksymalna wartość wyjściowa regulatora zostaje ograniczona do wartości $\max(\sum_j^i [\mu_j^i]) \cdot \max(w_j^i)$. Szczegółowy opis struktury sterowania z modelem odniesienia opisano w [11].

Metodologia doboru nastaw i parametrów projektowych regulatora

Liczba zmiennych wejściowych: liczba ta zależy od obiektu sterowania oraz typu sterowania jakie chcemy uzyskać. W analizowanych przypadkach użyto układów o jednym wyjściu oraz 2, 3 i 4 wejściach.

Liczba funkcji przynależności dla każdego z wejść: 3, 5, 7, 9. Jest to parametr projektowy wynikający z pożądanej gęstości podziału siatkowego przestrzeni sterowania. Dla każdego obiektu istnieje pewna liczba funkcji przynależności pozwalająca na najlepsze odwzorowanie funkcji pożądanej. W ogólności, im gęstszy podział siatkowy, czyli im więcej reguł, tym lepsze odwzorowanie. Jednocześnie większy rozmiar bazy reguł prowadzi do większej złożoności numerycznej algorytmu, niejednokrotnie uniemożliwiającej praktyczną implementację, bądź nieopłacalnego stosunku jakości regulacji do kosztów obliczeniowych.

Kształt funkcji przynależności: gaussowskie. Kształt funkcji przynależności w dużej mierze determinowany jest poprzez właściwości obiektu sterowania i preferencje projektanta.

Rozmieszczenie / parametry funkcji przynależności: funkcje są równomiernie rozłożone na przyjętej przestrzeni rozważań, przestrzeń rozważań w jednostkach względnych będzie rozciągać się od -1 do $+1$ dla każdej ze zmiennych wejściowych. Rozmieszczenie funkcji przynależności wynika z właściwości obiektu, w przypadku braku wiedzy najprostszym rozwiązaniem jest przyjęcie równomiernego rozłożenia funkcji, z parametrem szerokości (σ) dającym sumę wypadkową funkcji przynależności dla każdego z możliwych wejść możliwie bliską jedności.

Wzmocnienie sygnału wejściowego (K_{inn}) dla każdego z wejść powinno przeskalowywać sygnał tak, aby uzyskany zakres wartości pozwalał na sterowanie obiektem w założonym zakresie, ograniczenia dotyczące wartości wejścia ustawiono na $\mathcal{F}1$ z uwagi iż zgodnie z poprzednim założeniem taka jest rozciągłość użytej przestrzeni zmiennych. Wartości większe niż $\mathcal{F}1$ będą przez regulator traktowane jako maksymalnie duże.

W przypadku założonego układu o czterech wejściach parametrami projektowymi regulatora są: współczynniki skalujące dla wejść, odpowiednio K_e , K_{i_e} , $K_{\Delta e}$, K_{rek} . Współczynniki te dobrać można na podstawie dobranego modelu odniesienia. Model odniesienia jest elementem determinującym działanie układu, należy mieć na uwadze, iż trajektoria zadana w połączeniu z modelem odniesienia powinny generować sterowanie prowadzące do odtwarzania trajektorii zadanej w sposób możliwy do osiągnięcia przez obiekt z uwzględnieniem ograniczeń fizycznych. Takimi ograniczeniami są między innymi maksymalna wartość prądu.

Jeżeli warunek mówiący o trajektorii możliwej do śledzenia przez układ nie będzie spełniony może to spowodować nieprzewidzianą pracę układu. Jeżeli regulator adaptacyjny będzie regulatorem w zewnętrznej pętli sterowania (prędkość, położenie) natomiast w wewnętrznej pętli sterowania zastosowany zostanie dowolny inny regulator (prądu, momentu) zakładający ograniczenie maksymalnej wartości zadanej dla układu zasilania (np. prąd nie większy niż n -krotność prądu znamionowego) wówczas poprzez odpowiedni model odniesienia lub zadaną trajektorię

należy unikać pracy w nasyceniu lub chronić regulator adaptacyjny przez tym zjawiskiem na przykład poprzez zatrzymanie adaptacji w przypadku nasycenia lub ustawienie ograniczenia na maksymalne wartości współczynników wagowych.

Współczynnik K_e decyduje o wartości uchybu sterowania który będzie traktowany przez układ sterowania jako „duży”. W niniejszym przypadku dobrano $K_e = 1$. W takim wypadku różnica pomiędzy prędkością mierzoną, a zadaną co do modułu równa lub większa od prędkości znamionowej jest traktowana jako maksymalna wartość uchybu. Wewnątrz tego zakresu regulator będzie realizować zaimplementowaną funkcję sterowania.

Współczynnik $K_{\Delta e}$ odpowiada za skalowanie sygnału zmiany błędu sterowania. Zakładając, że obiekt sterowania daje się z zadowalającą dokładnością opisać za pomocą układu oscylacyjnego drugiego rzędu [2], [8], [11]. Dobór współczynnika $K_{\Delta e}$ powinien umożliwić operowanie w pełnym zakresie dynamiki osiągalnej przez obiekt. Chcąc przeskalować wartość sygnału do przestrzeni ± 1 należy dobrać wartość $K_{\Delta e} = 1/[\max(f'(t))]$. Mniejsza wartość $K_{\Delta e}$ spowoduje, że pewien obszar funkcji sterowania (pewne reguły regulatora rozmytego) nie będzie nigdy aktywny, co oznacza niewykorzystanie potencjału regulatora. Wartość większa spowoduje, że pewien zakres dynamiki będzie wykraczał poza zakres ± 1 w związku z tym nie wykorzystany będzie potencjał obiektu, co do maksymalnej wymuszanej dynamiki. Ograniczenie dynamiki może okazać się koniecznym między innymi dla przypadków gdzie należy ograniczać moment skrętny działający na sprzęg, aby go nie zerwać.

Przy doborze współczynnika K_{i_e} koniecznym jest założenie o stabilności i poprawności działania układu sterowania, należy również założyć, że żądana dynamika jest możliwa do osiągnięcia przez obiekt. W przeciwnym wypadku, gdy obiekt nie jest w stanie osiągnąć zadanej dynamiki, część całkowita (suma) dla błędu ustalonego będzie dążyć do nieskończoności, co w odpowiednio długim horyzoncie czasowym spowoduje utratę stabilności.

Zachowując powyższe założenia daje się wyznaczyć maksymalną wartość całki z błędu śledzenia sygnału zadanego jako różnica pomiędzy całką z sygnału zadanego, a teoretycznie wymuszaną dynamiką w postaci modelu odniesienia. W tym przypadku analogicznie do współczynnika $K_{\Delta e}$ współczynnik K_{i_e} może być tak dobrany, aby operować w pełnym lub niepełnym zakresie. W tym wypadku wartość graniczna to $K_{i_e} = 1/(\text{maksymalna występująca wartość } |e|)$. Dobór współczynnika powodujący rozszerzenie przestrzeni rozważań poza przestrzeń występujących wartości spowoduje niewykorzystanie części przestrzeni sterowań, co jest niezasadnym rozwiązaniem. Z uwagi na ograniczenie przestrzeni rozważań w warstwie wyznaczania poziomów spełnienia przesłanek powinno się również ograniczyć wartość integratora do wartości rozważanej przestrzeni zmiennej (tu $\mathcal{F}1$).

Współczynnik K_{rek} wprowadza sygnał wyjściowy na wejście regulatora, skalowanie powinno się odbywać ze współczynnikiem $K_{rek} = 1/(\max(wy(k-1)))$.

Metody wnioskowania i defuzyfikacji: wartości poziomów aktywacji reguł są iloczynami poziomów aktywacji składowych funkcji przynależności, poziomy te są następnie mnożone przez odpowiadające im współczynniki wagowe. Jako metody defuzyfikacji użyto klasycznej metody singletonów (7).

Algorytm adaptacji wraz ze współczynnikami: dla algorytmu postaci (6) koniecznym jest dobór współczynników K_{em} , $K_{\Delta em}$ decydujących o właściwościach algorytmu adaptacji, przy jednoczesnym uwzględnieniu warunków stabilności. Współczynniki te zgodnie z

warunkiem stabilności wynikającym z równania Lapunowa należy dobrać jako małe, dodatnie [13].

Jedną z możliwych metod jest dobór parametrów algorytmu adaptacji za pomocą algorytmów genetycznych, minimalizując zadane kryterium jakości sterowania.

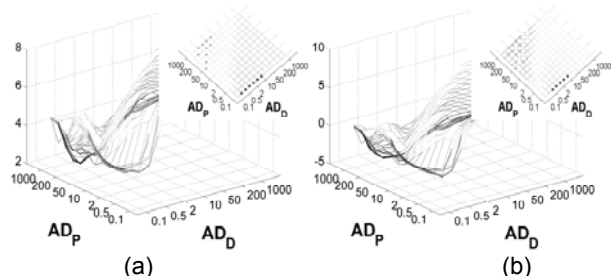
W związku z tym, iż układ jest adaptacyjny, co oznacza, że współczynniki wagowe powinny samodzielnie po pewnym czasie osiągnąć prawidłowe wartości, w chwili czasowej $t=0$ s wszystkie współczynniki wagowe są równe zero.

Z uwagi na proces adaptacji obejmujący istnienie całkowania, w przypadku nieprawidłowego doboru wartości współczynników K_{em} , K_{Aem} lub próby wymuszenia trajektorii niemożliwej do osiągnięcia przez układ, układ może prowadzić adaptację w nieskończoność. W związku z tym wprowadzone ograniczenia wartości współczynników wagowych. W przypadku regulatorów o liczbie reguł będących w stanie w sposób zadowalający odwzorować pożądaną funkcję sterowania ograniczenie to zostało ustawione jako $\pm 2 \cdot Y_{wy,max}$, w niniejszej pracy użyto ograniczenia wyjścia do poziomu $\pm 1,5 I_n$. Oznacza to w tym konkretnym przypadku poziom ograniczenia wag jako ± 3 . Należy także pamiętać o zatrzymaniu procesu adaptacji współczynników wagowych w przypadku nasycenia się współczynników i/lub wyjścia regulatora.

Warunkiem poprawnego działania układu jest wymuszenie trajektorii będącej możliwą do śledzenia przez układ. Szczególnie w przypadku trajektorii statycznej o amplitudzie niemożliwej do osiągnięcia przez układ, algorytm adaptacji będzie starał się zwiększyć wartości poszczególnych wag w nieskończoność, a w efekcie doprowadzi to do ich nasycenia.

Proces doboru nastaw adaptacji przebiegał w sposób następujący. W pierwszej kolejności symulacyjnie wyznaczone zostały ogólne płaszczyzny wartości kryteriów $ISE(e)$ oraz $IAE(e)$ gdzie $e = \omega_{mod} - \omega_s$ dla wektorów nastaw w postaci: [0,1 0,2 0,5 1 2 5 10 20 50 100 200 500 1000] dla regulatorów o 3, 5, 7, 9 funkcjach przynależności przyporządkowanych każdemu z wejść (4 przypadki), dla regulatorów typu PD oraz PID (*2), z rekurencją od wyjścia do wejścia oraz bez rekurencji (*2), z oraz bez warstwy tranzycji (*2) – w sumie $4 \cdot 2 \cdot 2 \cdot 2 = 32$ przypadki. Płaszczyzny te zaprezentowano na rys. 2.

Na podstawie znajomości ogólnych płaszczyzn kryteriów wytypowano ograniczenia przestrzeni poszukiwań dla algorytmów Pattern Search (PS) oraz Particle Swarm Optimization (PSO). Oraz punkt początkowy dla PS ($K_{em}=500$ $K_{Aem}=0,5$). Algorytm PSO opisano w [14], [15], [16], [17], natomiast PS w [18], [19].



Rys.2. Złożenie siatek wartości $\log(IAE(e))$ (a) oraz $\log(ISE(e))$ (b) w funkcji wartości parametrów adaptacji wraz z zaznaczonymi ekstremami

Jak można zauważyć analizując tabelę 1 znacznie lepsze wartości wskaźnika jakości dały przypadki regulatora z rekurencją. Pięć najlepszych przypadków zaznaczono

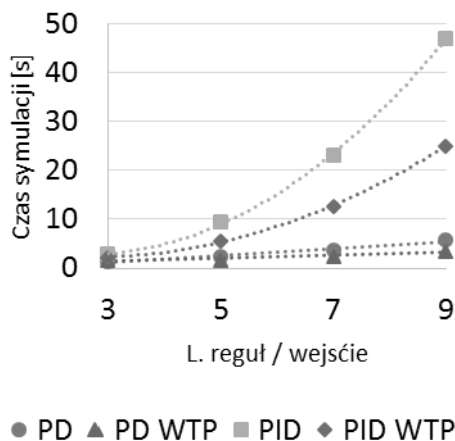
lekkim szarym tłem oraz pogrubieniem natomiast pięć najgorszych szarym tłem oraz kursywą.

W toku badań symulacyjnych wykonane zostały pomiary czasów koniecznych do obliczenia serii symulacji z udziałem poszczególnych regulatorów. Seria składała się z piętnastu pięcio-sekundowych symulacji z krokiem obliczeniowym 0.0001s ($7,5 \cdot 10^5$ iteracji). Na rys. 3 i 4 zaprezentowano czasy wykonania się serii dla przypadku regulatorów bez (rys. 3) oraz z rekurencjami (rys.4).

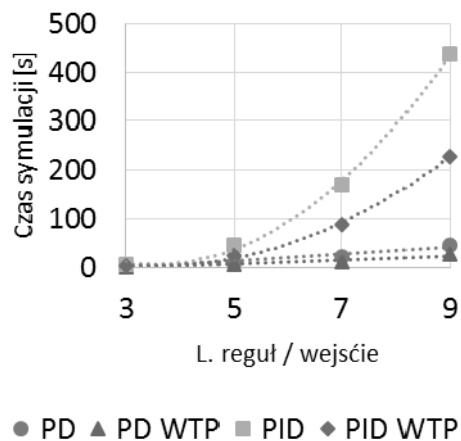
Rysunki 5, 6 oraz 7 prezentują przebiegi wybranych zmiennych stanu układu dwumasowego z regulatorami odpowiednio regulator PD bez rekurencji i bez WTP o 3 funkcjach przynależności na wejście na rysunku 5. (tabela 1 l.p. 9), regulator PID z rekurencją oraz z WTP o 5 funkcjach przynależności na wejście na rysunku 6. (tabela 1. l.p. 30) oraz regulator typu PD z rekurencją bez WTP o 9 funkcjach przynależności na wejście (tabela 1. l.p. 28). Zmiennymi pokazanymi są prędkość modelu referencyjnego oraz śledzące je prędkość maszyny roboczej i obciążenia, różnica pomiędzy prędkością modelu referencyjnego a maszyny roboczej oraz zadany oraz mierzony prąd twornika.

Tabela 1. Wyniki optymalizacji nastaw adaptacji regulatorów


L.p.	ISE (PSO)	ISE (PS)	Reg	Rekurencja
1	0,1628	0,171	PD 3 reg/we WTP	NIE
2	0,1869	0,200	PD 5 reg/we WTP	NIE
3	0,1992	0,189	PD 7 reg/we WTP	NIE
4	0,1644	0,222	PD 9 reg/we WTP	NIE
5	0,1777	0,168	PID 3 reg/we WTP	NIE
6	0,1823	0,186	PID 5 reg/we WTP	NIE
7	0,2011	0,181	PID 7 reg/we WTP	NIE
8	0,1867	0,219	PID 9 reg/we WTP	NIE
9	0,1785	0,176	PD 3 reg/we	NIE
10	0,1821	0,182	PD 5 reg/we	NIE
11	0,1805	0,183	PD 7 reg/we	NIE
12	0,1905	0,478	PD 9 reg/we	NIE
13	0,1771	0,174	PID 3 reg/we	NIE
14	0,1818	0,181	PID 5 reg/we	NIE
15	0,1878	0,238	PID 7 reg/we	NIE
16	0,1868	0,184	PID 9 reg/we	NIE
17	0,1450	0,172	PD 3 reg/we WTP	TAK
18	0,1628	0,153	PD 5 reg/we WTP	TAK
19	0,1509	0,154	PD 7 reg/we WTP	TAK
20	0,1640	0,146	PD 9 reg/we WTP	TAK
21	0,1552	0,160	PID 3 reg/we WTP	TAK
22	0,1550	0,168	PID 5 reg/we WTP	TAK
23	0,1747	0,164	PID 7 reg/we WTP	TAK
24	0,1400	0,142	PID 9 reg/we WTP	TAK
25	0,1712	0,153	PD 3 reg/we	TAK
26	0,1613	0,160	PD 5 reg/we	TAK
27	0,1723	0,148	PD 7 reg/we	TAK
28	0,1220	0,153	PD 9 reg/we	TAK
29	0,1555	0,163	PID 3 reg/we	TAK
30	0,1645	0,134	PID 5 reg/we	TAK
31	0,1483	0,153	PID 7 reg/we	TAK
32	0,1435	0,143	PID 9 reg/we	TAK




Rys.3. Czasy wykonania się serii symulacyjnej dla przypadku regulatorów bez rekurencji




Rys.4. Czasy wykonania się serii symulacyjnej dla przypadku regulatorów z rekurencjami



Rys.5. Przebiegi prędkości modelu odniesienia, napędu oraz obciążenia (a), różnicy pomiędzy modelem odniesienia, a prędkością napędu oraz prądów twornika (c) dla przypadku układu z regulatorem typu PD bez rekurencji i bez WTP o 3 f. przynależności na wejście. Parametry adaptacji dobrane metodą pattern search



Rys.6. Przebiegi prędkości modelu odniesienia, napędu oraz obciążenia (a), różnicy pomiędzy modelem odniesienia, a prędkością napędu oraz prądów twornika (c) dla przypadku układu z regulatorem typu PID z rekurencją oraz WTP o 5 f. przynależności na wejście. Parametry adaptacji dobrane metodą pattern search



Rys.7. Przebiegi prędkości modelu odniesienia, napędu oraz obciążenia (a), różnicy pomiędzy modelem odniesienia, a prędkością napędu oraz prądów twornika (c) dla przypadku układu z regulatorem typu PD z rekurencją bez WTP o 9 f. przynależności na wejście. Parametry adaptacji dobrane metodą PSO

Wyniki badań i wnioski

Wykreślone zostały siatki kryteriów jakości w zależności od nastaw adaptacji. Siatki dla kryteriów IAE (całka z modułu błędu) oraz ISE (całka z kwadratu błędu) gdzie Y oznacza logarytm naturalny różnicy pomiędzy prędkością modelu referencyjnego, a prędkością mierzoną. Siatki wykreślono w funkcji parametrów adaptacji AD_P - K_{em} , AD_D -

K_{Aem} . Skala logarymiczna osi Y została użyta ze względu na czytelność rysunku.

Symulacje przeprowadzono dla wektorów obu nastaw z zakresu [0,1 - 1000] dla regulatorów 3, 5, 7, 9 reguł na każde z wejść (4 przypadki) dla regulatorów PD oraz PID, z rekurencją od wyjścia do wejścia oraz bez rekurencji, z oraz bez warstwy tranzycji. W efekcie przebadano 32 przypadki regulatorów.

Wszystkie uzyskane płaszczyzny są podobne, w związku z tym na ich podstawie zdecydowano się dobrać punkt startowy do dalszej optymalizacji nastaw za pomocą algorytmów PS oraz PSO. Jako punkt startowy dla PS wykorzystano punkt $K_{em}=500$ $K_{dem}=0.5$, w przypadku PSO zakres poszukiwań dla obu zmiennych ustawiono jako 0-1000). Jako kryterium optymalizacji wybrano sumę kwadratów błędów odtwarzania prędkości modelu. W tabeli 1. zestawiono wartości kryterium dla nastaw parametrów adaptacji uzyskanych w wyniku optymalizacji.

Na podstawie tabeli 1. Można stwierdzić, iż regulatory z rekurencją oferują lepszą jakość sterowania w przypadku kryterium jakości zdefiniowanego jako ISE. Najlepszym uzyskanym przypadkiem z uwzględnieniem optymalizacji pattern search jest przypadek z regulatorem typu PID z rekurencją oraz WTP o 5 f. przynależności na wejście, przebiegi zmiennych stanu dla tego przypadku zaprezentowano na rysunku 8. Na rysunku 7. Zaprezentowano przypadek odniesienia, układ z regulatorem typu PD bez rekurencji i bez WTP o 3 f. przynależności na wejście

Analizując rysunki 3. oraz 4. można zaobserwować tendencję do wzrostu czasu obliczeń wraz ze wzrostem liczby wejść oraz funkcji przynależności przyporządkowanej każdemu z tych wejść. Jednocześnie widać, iż zastosowanie WTP znacznie obniża tempo tego wzrostu. Regulator z WTP dowolnego typu z dziewięcioma funkcjami przynależności na wejście oferuje zbliżony lub mniejszy czas obliczeń aniżeli analogiczny regulator bez WTP o pięciu regułach przynależności na wejście.

Co istotne należy zauważyć, iż najgorsze wartości dla przypadku optymalizacji pattern search dały przypadki regulatorów bez rekurencji, z pełnym oknem z odpowiednio 7 i 9 regułami, co znaczy że nie zawsze większa liczba f. przynależności poprawia jakość sterowania.

W przypadku metody PSO zastosowano rój o liczności 10 cząstek, oznacza to konieczność wykonania 10 symulacji dla każdej iteracji, w przypadku metody pattern search i dwóch zmiennych optymalizowanych, dla każdej iteracji wykonane są 4 symulacje. W przypadku PSO minimum osiągnięte było po nie więcej niż kilkunastu (15) iteracjach, natomiast algorytm pattern search do wyniku końcowego dochodził zazwyczaj około 25. iteracji. Wyniki minimalizacji kryterium w oby przypadkach były zbliżone. Co ważne oba algorytmy uzyskały najlepsze wartości zaproponowanego kryterium jakości dla przypadków regulatorów z rekurencjami, a najgorsze dla regulatorów bez rekurencji.

Praca współfinansowana przez Narodowe Centrum Nauki w ramach projektu Adaptacyjne sterowanie rozmyte złożonego układu napędowego o zmiennych parametrach, 2012-2015, UMO-2011/03/B/ST7/02517

Wyniki obliczeń zamieszczone w niniejszym opracowaniu uzyskano dzięki infrastrukturze projektu PLATON w Centrum Komputerowym Politechniki Łódzkiej

Autorzy: mgr. inż. Piotr Derugo, dr hab. inż. Krzysztof Szabat prof. PWr, Politechnika Wroclawska, Katedra Maszyn Napędów i Pomiarów Elektrycznych, Wybrzeże Wyspiańskiego 27, 50-370 Wrocław, E-mail: piotr.derugo@pwr.wroc.pl, krzysztof.szabat@pwr.wroc.pl

dr inż. Jarosław Kacerka, Politechnika Łódzka, Instytut Automatyki, Zakład Teorii Sterowania, 90-924 Łódź, ul. B. Stefanowskiego 18/22, jaroslaw.kacerka@p.lodz.pl

LITERATURA

- [1] Jastrzębski M., Sterowanie adaptacyjne silnikiem liniowym z neuronowym kompensatorem tarcia strojonym on-line, *Przegląd Elektrotechniczny*, 90 (2014), nr 6, 61-66
- [2] Derugo P., Szabat K., Adaptive neuro-fuzzy PID controller for nonlinear drive system, *COMPEL: The International Journal for Computation and Mathematics in Electrical and Electronic Engineering* 34 (2015), n.3, 792-807
- [3] Li H., et al. Adaptive sliding-mode control for nonlinear active suspension vehicle systems using T-S fuzzy approach, *IEEE Transactions on Industrial Electronics*, 60 (2013), n.8, 3328-3338
- [4] Iwasaki M., Kenta S., Yoshihiro M., High-precision motion control techniques: a promising approach to improving motion performance, *IEEE Industrial Electronics Magazine*, 6 (2012), n.1, 32-40
- [5] Knychas S., Derugo P., Szabat K., Damping of the torsional vibration using adaptive fuzzy control system with different recurrences, *IEEE 23rd International Symposium on Industrial Electronics (ISIE)*, (2014),
- [6] Knychas S., Szabat K., Adaptacyjny układ sterowania z rekurencyjnymi regulatorami rozmytymi dla układu napędowego o zmiennych parametrach, *Przegląd Elektrotechniczny* 89 (2013).
- [7] Derugo P., Szabat K., Implementation of the Low Computational Cost Fuzzy PID Controller for Two-Mass Drive System, *proceedings of PEMC (2014)*, 661-665
- [8] Derugo P., et al., Sterowanie silnikiem liniowym z wykorzystaniem adaptacyjnej struktury sterowania z regulatorem rozmytym typu PID, *Przegląd Elektrotechniczny*, 91 (2015), nr 7, 93-96
- [9] Derugo P., Kacerka J., Jastrzębski M., Szabat K. Sterowanie silnikiem liniowym z wykorzystaniem adaptacyjnej struktury sterowania z regulatorem rozmytym typu PID, *Przegląd Elektrotechniczny*, 91 (2015), nr 7, 93-96
- [10] Derugo P., Szabat K., Algorytm implementacji regulatora rozmytego o niskim koszcie numerycznym. *Przegląd Elektrotechniczny*, 90 (2014), nr 11, 235-238
- [11] Szabat K., Struktury sterowania elektrycznych układów napędowych z połączeniem sprężystym, *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej. Monografie* 61.19 (2008).
- [12] Kabziński J., Kacerka J., TSK Fuzzy Modeling with Nonlinear Consequences, *Artificial Intelligence Applications and Innovations*, (2014), 498-507
- [13] Orłowska-Kowalska T., Szabat K., Control of the drive system with stiff and elastic couplings using adaptive neuro-fuzzy approach, *IEEE Transactions on Industrial Electronics*, 54 (2007), n.1, 228-240
- [14] Kennedy J., Eberhart R., Particle swarm optimization., *IEEE Int. Conf. on Neural Networks*, (1995),
- [15] Shi Y., Eberhart R.: Parameter selection in particle swarm optimization, *Proc. 7th Annual Conf. on Evolutionary Programming*, (1998)
- [16] Kacerka J., Jastrzębski M. Rozmyte modelowanie strumienia magnetycznego, z wykorzystaniem algorytmów ewolucyjnych, materiały konferencyjne Krajowa Konferencja Automatyki, (2011), 372-379
- [17] Shi Y., Eberhart R.: A modified particle swarm optimizer, *Proc. of the IEEE World Congress on Computational Intelligence*, (1998)
- [18] Audet Ch., Dennis J. E. Jr. Analysis of generalized pattern searches. *SIAM Journal on Optimization*, 13 (2002), n.3, 889-903
- [19] Torczon V., On the convergence of pattern search algorithms. *SIAM Journal on optimization* 7 (1997), n.1, 1-25