

Modelowanie dwurotorowego systemu aerodynamicznego z wykorzystaniem systemu neurorozmytego

Piotr Woźnica

Instytut Automatyki i Informatyki, Politechnika Opolska

Streszczenie: W artykule przedstawiono propozycję modelu neurorozmytego dla złożonego obiektu nieliniowego. Ze względu na osobliwości modeli analitycznych, zasugerowano strukturę rozmytą z adaptacyjnym doбором parametrów. Opracowano koncepcję adaptacyjnego obserwatora rozmytego, działającego na podstawie stworzonego modelu neurorozmytego. Dokonano oceny efektywności modelu i estymatora adaptacyjnego pod względem złożoności konstrukcji i nakładu obliczeniowego. Procedura implementacji modelu została przeprowadzona z użyciem środowiska obliczeniowego MATLAB.

Słowa kluczowe: TRAS, dwurotorowy system aerodynamiczny, system neurorozmyty, estymacja stanu

DOI: 10.14313/PAR_208/86

Modele procesów w problemach sterowania i diagnostyki są istotnym elementem w przebiegu poznawania zjawisk zachodzących w tych procesach. Przydatność modelu do określonego celu wyznacza się arbitralnie na podstawie szeregu kompromisów uzyskując model o wysokiej efektywności dla wyznaczonego zadania. W zaawansowanych układach regulacji modele analityczne często stają się mało efektywne pod względem szybkości przetwarzania, a także czasochłonności implementacji. Wyznaczenie równań opisujących zjawiska zachodzące w rzeczywistym obiekcie wymaga przeprowadzenia dokładnego procesu poznawczego. Konieczna jest też znajomość odpowiedniego aparatu matematycznego. Alternatywą dla modeli analitycznych może być model neurorozmyty utworzony w trakcie identyfikacji procesu. Model z wykorzystaniem technik neuronowych pozwala na szybką implementację oraz odznacza się wysoką efektywnością w zastosowaniach do diagnostyki i sterowania złożonych obiektów.

Badania modelowe przeprowadzono na bazie modelu laboratoryjnego dwurotorowego systemu aerodynamicznego TRAS (ang. *Two Rotor Aerodynamical System*) stanowiącego wyposażenie laboratorium podstaw automatyki w Instytucie Automatyki i Informatyki Politechniki Opolskiej. Badany obiekt jest kompletnym stanowiskiem laboratoryjnym. Obsługa programowa systemu jest realizowana w środowisku MATLAB/Simulink [2].

W artykule opisano i przedstawiono metodę modelowania z wykorzystaniem technik sztucznej inteligencji. Przesłanką do realizacji modelu w postaci struktury neurorozmytej jest wykorzystanie w nieliniowym estymatorze stanu pełnego rzędu. Zaproponowano strukturę estymatora stanu pełnego rzędu o właściwościach adaptacyjnych. Ideą estymatora adaptacyjnego jest implementacja macierzy korekcyjnej w strukturze neurorozmytej.

1. Wprowadzenie

Na złożoność modelu obiektu wpływa w istotny sposób jego statyka. Właściwe odwzorowanie właściwości statycznych zaraz obok dynamiki obiektu jest kluczowym działaniem dla uzyskania wysokiej efektywności modelu. W dalszej części zostanie przedstawiony uproszczony model w przestrzeni stanu dla wybranego obiektu mechatronicznego, którym jest dwurotorowy system aerodynamiczny w celu dokonania analizy porównawczej.

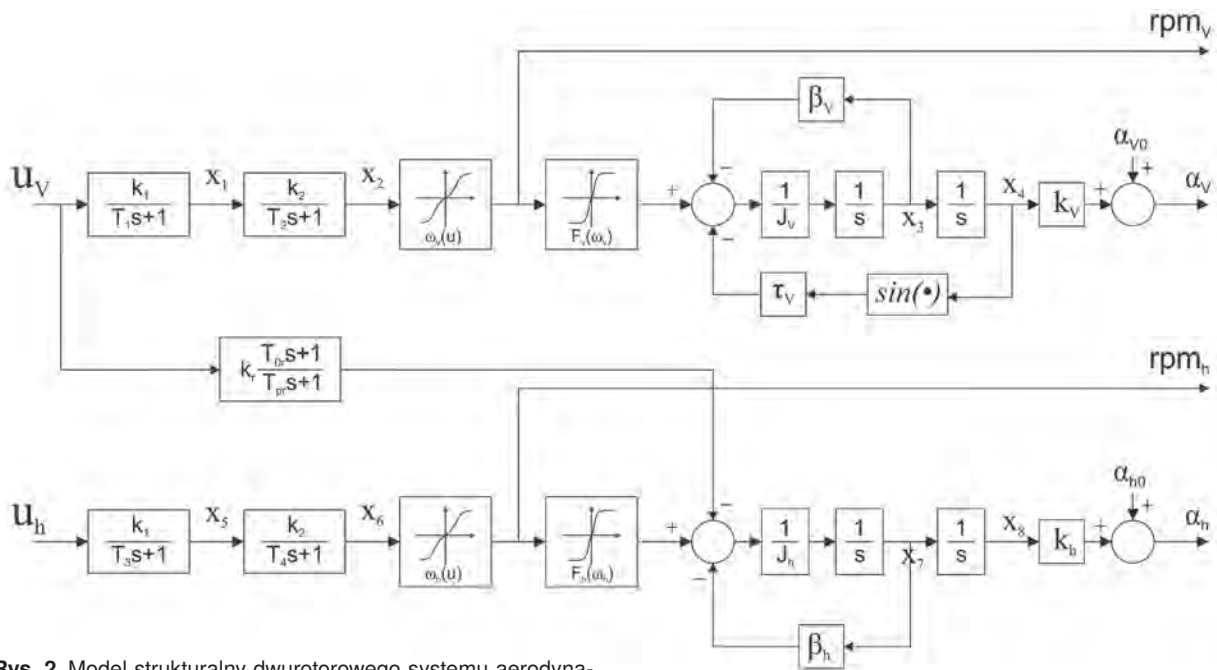
Ze względu na silne nieliniowości wprowadzane przez zespoły napędowe oraz tarcia związane z dwustopniowym ruchem belki, modelowanie prezentowanego obiektu jest złożonym zadaniem.

Omawiany obiekt można analizować jako nieliniowy układ MIMO o dwóch wejściach i dwóch wyjściach. Sygnałami sterującymi są napięcia doprowadzone do silników napędowych u_h oraz u_v , sygnałami wyjściowymi kąty nachylenia α_h , α_v oraz prędkości obrotowe wirników zespołów napędowych rpm_h i rpm_v . Dla uproszczenia analizy rozłożono system wielowymiarowy na człony/tory jednowymiarowe i dla tak rozdzielonej struktury przeprowadzono syntezę modelu analitycznego.



Rys. 1. Dwurotorowy system aerodynamiczny

Fig. 1. Two rotor aerodynamical system



Rys. 2. Model strukturalny dwurotorowego systemu aerodynamicznego

Fig. 2. Structural model of two rotor aerodynamical system

Model analityczny jednego z członów jednowymiarowych składa się z czterech równań różniczkowych zwyczajnych (1) [1]. Równania opisują stan dla zerowych warunków początkowych. Poszczególne zmienne stanu reprezentują następujące wielkości: x_1 – zmienna stanu silnika prądu stałego, x_2 – prędkość obrotowa wału silnika, x_3 – moment obrotowy belki, x_4 – położenie kątowe belki. Pozostałe tory systemu opisano analogicznie.

$$\begin{cases} \dot{x}_1 = -\frac{1}{T_1} x_1 + \frac{1}{T_1} u_1 \\ \dot{x}_2 = -\frac{1}{T_2} x_2 + \frac{1}{T_2} x_1 \\ \dot{x}_3 = \frac{1}{I_\alpha} (a_1 x_2^2 + b_1 x_2 - b_\alpha x_3 - \tau_y \sin x_4) \\ \dot{x}_4 = x_3 \end{cases} \quad (1)$$

Na rys. 2 przedstawiono model strukturalny obiektu w postaci układu MIMO uwzględniający sprzężenie skrosne. Nieliniowość obiektu została przedstawiona w postaci prędkości obrotowej w funkcji napięcia zasilającego oraz siły ciągu w zależności od prędkości obrotowej wirnika.

2. Koncepcja modelu neurorozmytego system TRAS

Model analityczny obiektu nie jest wystarczająco efektywny podczas realizacji układu regulacji. Model matematyczny w postaci równań różniczkowych zwyczajnych wzbogacono o statyczne modele neurorozmyte.

Systemy oparte na logice rozmytej, znajdują zastosowanie szczególnie tam, gdzie konstrukcja modelu jest złożona. Przy rosnącej złożoności modelowanych procesów zwiększa

się zbiór rozmytych reguł i funkcji przynależności. Powyższe wady doprowadziły do wprowadzenia systemów neurorozmytych. Systemy rozmyte mają zdolność do interpretacji nieprecyzyjnych i niepełnych danych, a sieci neuronowe mają zdolność uczenia się i tworzenia nowych reguł, które uzupełniają brakujące dane. Hybryda złożona z obu systemów znalazła obecnie szerokie zastosowanie w procesach modelowania.


Strukturę sieci neuronowej odzwierciedlającej system rozmyty przedstawiono na rys. 3. Sieć taką można interpretować jako perceptron wielowarstwowy, w którego strukturze nieliniowe węzły neuronów można przyjąć jako nieliniowe funkcje przynależności [4].

Sieć składa się z ośmiu warstw: trzy pierwsze warstwy odnoszą się do funkcji przynależności i realizują wyznaczenie poziomów aktywacji $w^i(x)$, gdzie w węzłach warstwy drugiej zaimplementowane są funkcje nieliniowe $g(z)$. Kolejna czwarta warstwa, której węzły oznaczone są symbolem „II” realizuje funkcję mnożenia. Węzły warstwy piątej realizują proces obliczania wartości funkcji $f_i(x)$ następników reguł. Warstwy od szóstej do ósmej realizują konkluzję wg wzoru (2). Wykorzystana sieć neuronowa jest statyczną strukturą pozwalającą na aproksymację dowolnych zależności nieliniowych interpretowanych w strukturze rozmytej.

Wyjście systemu neurorozmytego opisane jest zależnością (2), gdzie $\tilde{w}^i(x)$ oznacza unormowane poziomy aktywacji reguł, R jest liczbą reguł.

$$y = \frac{\sum_{i=1}^R w^i(x) \cdot y^i}{\sum_{i=1}^R w^i(x)} = \sum_{i=1}^R \tilde{w}^i(x) \cdot y^i \quad (2)$$

Ideą stosowania sieci neurorozmytych jest możliwość adaptacji parametrów i struktury systemu rozmytego dzięki wykorzystaniu metod znanych z uczenia sieci




Rys. 3. Reprezentacja systemu rozmytego z jedną zmienną wejściową i trzema regułami w postaci rozmytej sieci neuronowej [4]
Fig. 3. Representation of fuzzy system with one input variable and the three rules in the form of fuzzy neural network

neuronowych. Uczenie i optymalizacja parametrów sieci neuronowych jest zadaniem mniej złożonym w porównaniu do procesu uczenia i optymalizacji struktury i parametrów systemu rozmytego. Powyższa metoda jest stosowana jedynie w przypadku znanego zbioru danych uczących lub znanej zależności nieliniowej, co jednocześnie ogranicza stosowalność prezentowanego działania. System ANFIS (ang. *Adaptive Neuro Fuzzy Inference System*) wymaga zdefiniowania liczby i postaci funkcji przynależności oraz postaci konkluzji, tzn. wartości stałej lub funkcji liniowej.

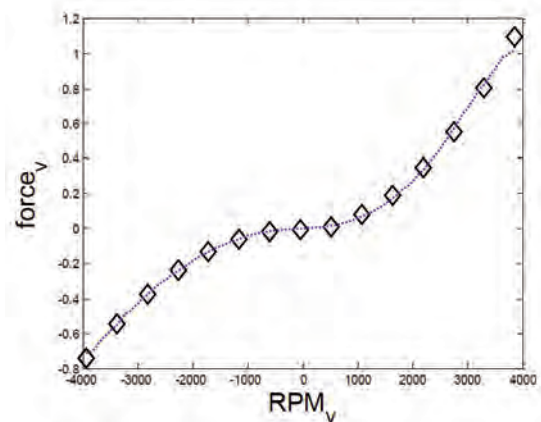
W przeprowadzonych eksperymentach przyjęto funkcje przynależności o postaci sigmoidalnej definiowanej wzorem:

$$\mu_{X_i}(x) = \frac{1}{1 + \exp[-\alpha_i(x - c_i)]} \quad (3)$$


Zależność (3) opisuje funkcję przynależności jednostronną, gdzie parametry α_i i c_i określają kształt zbioru rozmytego X_i .



Rys. 4. Początkowe funkcje przynależności zbiorów rozmytych modelu charakterystyki nieliniowej
Fig. 4. The initial membership functions of nonlinear characteristics



Rys. 6. Wynik procesu modelowania nieliniowej charakterystyki statycznej systemu TRAS (kropki – charakterystyka rzeczywista, diamenty – odwzorowanie przez strukturę neurorozmytą)
Fig. 6. Results of modelling process of nonlinear static characteristic of TRAS system (dots – real characteristic, diamond – mapping by neurofuzzy structure)



Rys. 5. Funkcje przynależności zbiorów rozmytych modelu charakteryzujące nieliniowe po procesie optymalizacji

Fig. 5. The membership functions of fuzzy model nonlinear characteristic after optimization process


Funkcja dwustronna jest tworzona z dwóch funkcji jednostronnych przez odjęcie od siebie dwóch funkcji lewostronnie lub prawostronnie otwartych odpowiednio usytuowanych względem siebie.

W wyniku przeprowadzonej syntezy z początkową postacią funkcji przynależności z rys. 4 oraz uczenia modelu neurorozmytego otrzymano funkcje przynależności przedstawione na rys. 5. W efekcie działania algorytmu optymalizacji funkcji przynależności, otrzymano trzy funkcje sigmoidalne o różnych położeniach i kształtach. Optymalizacji podlegają współczynniki α_i i c_i ; α_i określa stromość funkcji, gdzie dla $\alpha_i > 0$ funkcja jest prawostronnie otwarta, dla $\alpha_i < 0$ funkcja jest lewostronnie otwarta, natomiast c_i wyznacza położenie funkcji.

Na rys. 6 przedstawiono wynik modelowania charakterystyki statycznej omawianego obiektu. W realizacji procesu uczenia sieci neurorozmytej wykorzystano algorytm hybrydowy uczenia sieci neuronowych składający się z dwóch współdziałających metod, tzn. metody wstecznej propagacji błędów oraz metody najmniejszych kwadratów. Wyboru takiego algorytmu dokonano ze względu na szybkość zbieżności oraz wysoką efektywność.


Model systemu dla jednego z torów przedstawiono na rys. 7. Struktura systemu składa się z macierzy A, B, C oraz struktur neurorozmytych wyznaczonych w procesie adaptacji neuronowej, które oznaczono jako funkcje $f(x)$ oraz $g(x)$. Należy zaznaczyć, że funkcja oznaczona $f(x)$ (rys. 7) nie jest tożsama z funkcją $f_i(x)$ następnika reguły rozmytej.

Na rys. 8 zamieszczono przebiegi otrzymanych położenia kątownych belki systemu TRAS dla rzeczywistego obiektu oraz modelu neurorozmytego, z którego wynika dobra dokładność estymowanego położenia kątownego. Największy błąd występuje w fazie rozruchu lub zmiany kierunku obrotu. Mimo obecności zakłóceń wynikających z różnych etapów pracy systemu i wynikających z tego ograniczeń, efektywność modelu neurorozmytego umożliwia stosowanie go w modelowaniu systemów nieliniowych.



Rys. 7. Model rozmyty systemu TRAS

Fig. 7. Fuzzy model of TRAS system



Rys. 8. Wykresy położenia belki systemu dla obiektu rzeczywistego i modelu neurorozmytego

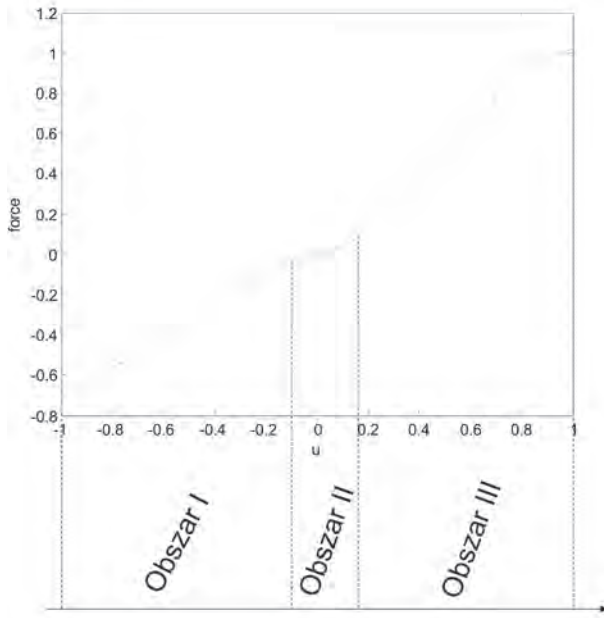
Fig. 8. Charts beam position of system for real plant and neurofuzzy model

4. Estymator rozmyty

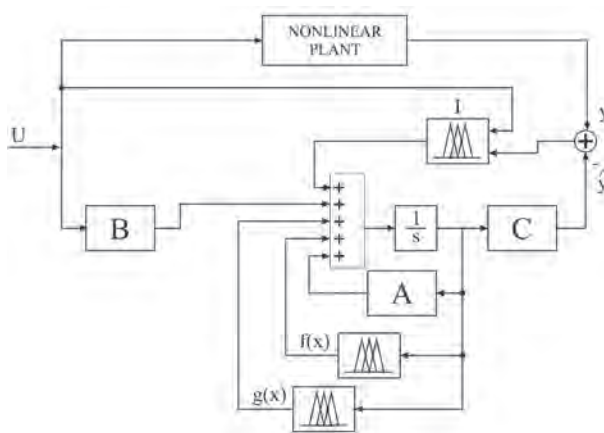
Estymator stanu stanowi technikę odtwarzania zmiennych stanu, które nie są dostępne pomiarowo. Obserwatory liniowe, zaprojektowane ściśle do wybranego liniowego lub zlinearyzowanego systemu, nie są wystarczająco efektywne w przypadku wykorzystania w rzeczywistych systemach silnie nieliniowych [10, 11]. Z tego względu powstaje przesłanka do realizacji nieliniowego estymatora stanu o dużej efektywności w zastosowaniu do systemu nieliniowego. Zarówno w procesach sterowania, jak i diagnostyki systemu nieliniowego istnieje potrzeba precyzyjnej estymacji stanu ze względu na konieczność zapewnienia wysokiej efektywności pracy ww. układów [8, 9].

Obserwator liniowy Luenbergera opisany jest równaniem (4). W przypadku systemu liniowego macierz I jest macierzą o stopniu równym rzędowi modelu opisującego obiekt. Dobór współczynników wektora wzmocnień sprowadza się do ustalenia wartości własnych macierzy (A-IC) [7].

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + Bu(t) + I(\hat{x}, u)[y - \hat{y}] \\ \hat{y} = C\hat{x} \end{cases} \quad (4)$$



Rys. 9. Podział obszarowy charakterystyki nieliniowej
 Fig. 9. Territorial division of non-linear characteristic



Rys. 10. Rozmyty estymator stanu
 Fig. 10. Fuzzy state estimator

Podczas realizacji obserwatora nieliniowego (rys. 10) należy analizować cały przedział zmienności wartości zmiennych stanu i wejścia. Współczynniki korektora I dla wybranych punktów pracy systemu wyznaczono arbitralnie dzieląc na podstawie doświadczeń obszar pracy systemu na podprzedziały (rys. 9), dla których przeprowadzono oddzielnie syntezy liniowych obserwatorów Luenbergera. Uzyskane wartości macierzy korekcji wykorzystuje się w realizacji rozmytego obserwatora nieliniowego.

Dla przypadku obserwatora nieliniowego macierz I zastąpiono strukturą rozmytą. Struktura ta składa się z dwóch wejść oraz n wyjść, gdzie n jest rzędem modelu opisującego obiekt (rys. 11). Korektor składa się z dwóch zbiorów rozmytych dla funkcji błędu estymacji oraz wartości sygnału wymuszenia, który determinuje punkt pracy systemu.


W członie rozmytym I zaimplementowano wartości uzyskane w procesie syntezy obserwatorów rozmytych, które stanowią wartości współczynników konkluzji struktury rozmytej. Następnie ww. struktury mają postać stałych wartości.

Baza reguł struktury korektora I składa się z dwunastu elementów o postaci:

- R^1 : JEŻELI u jest Obszar1 TO $i^1 = a_0^1$
- R^2 : JEŻELI u jest Obszar1 TO $i^2 = a_0^2$
- R^3 : JEŻELI u jest Obszar1 TO $i^3 = a_0^3$
- R^4 : JEŻELI u jest Obszar1 TO $i^4 = a_0^4$
- R^5 : JEŻELI u jest Obszar2 TO $i^1 = a_1^1$

R^{12} : JEŻELI u jest Obszar3 TO $i^4 = a_2^4$

Dobór współczynników korektora jest kompromisem między odpornością estymatora na zakłócenia (szumy), wówczas przyjmuje się duże wzmocnienie korektora, a wzmocnieniem zakłóceń, w przypadku małego wzmocnienia korektora.




Rys. 11. Schemat struktury korektora rozmytego
 Fig. 11. Schematic structure of fuzzy corrector

System rozmytego obserwatora stanu dokonuje adaptacji współczynników wzmocnienia korektora I do aktualnego punktu pracy obiektu. Błąd obserwacji ($y - \hat{y}$) podawany na wejście korektora rozmytego jest rozwiązaniem klasycznym, natomiast dodatkowo informacja o wartości sygnału wejściowego pozwala na adaptację obserwatora oraz zwiększa szybkość jego działania. W zaproponowanym rozwiązaniu etap parametryzacji struktury rozmytej można rozpocząć od zera z równoczesnym zachowaniem stabilności układu zamkniętego, wynikającej z odpowiedniego doboru poszczególnych macierzy wzmocnień I. Zastosowanie układu z logiką rozmytą wprowadza formę liniową aproksymowanej macierzy korekcyjnej przez wprowadzenie podstawowych składowych macierzy liniowych [6].

Na rys. 12 przedstawiono wyniki symulacji rozmytego estymatora stanu dla dwurotorowego systemu aerodynamicznego.

5. Wnioski

Dzięki wykorzystaniu metody adaptacyjnego doboru parametrów struktury rozmytej (ANFIS), poprawiono efektywność modelu dwurotorowego systemu aerodynamicznego pod względem przydatności w systemie obserwacji



Rys. 12. Wykres przebiegów zmiennych stanu obiektu (niebieski) oraz zmiennych estymowanych (czerwony)

Fig. 12. Chart of courses state plant variables (blue) and the estimated variables (red)

stanu [1]. Istotnym problemem w implementacji modelu rozmytego jest wymagana duża liczba dobieranych parametrów. Wykorzystując metody znane z uczenia sieci neuronowych, automatyzuje się proces doboru struktury i wyznaczenia parametrów, co istotnie przyspiesza proces strojenia modelu, a także zwiększa efektywność pod względem jakości odwzorowania. Metoda automatycznej identyfikacji modelu neurorozmytego pozwala na uproszczenie procesu konstrukcji modelu oraz skraca czas implementacji modelu przy zachowaniu wysokiej efektywności.

Odwzorowanie macierzy korekcyjnej estymatora stanu w strukturze rozmytej pozwala uwzględnić wpływ nieliniowości obiektu na efektywność estymacji pod względem wartości uchybu wartości mierzonej i estymowanej.

Bibliografia

1. Woźnica P., *Problemy sterowania rozmytego wybranym obiektem nieliniowym na przykładzie dwurotorowego systemu aerodynamicznego – wybrane zagadnienia*, praca magisterska, Wydział Elektrotechniki, Automatyki i Informatyki, Politechnika Opolska, Opole 2013.
2. INTECO, *Two rotor aero-dynamical system. User's manual*, Kraków 2009.
3. Korbicz P., Kościelny J.M., *Modelowanie, diagnostyka i sterowanie nadrzędne procesami. Implementacja w systemie DiaSter*, WNT, Monografie, Tom 14, Warszawa 2009.
4. Tatjewski P., *Sterowanie zaawansowane obiektów przemysłowych. Struktury i algorytmy*, EXIT, Monografie, Tom 5, Warszawa 2002.

5. Łęski J., *Systemy neuronowo-rozmyte*, WNT, Warszawa 2008.
6. Giergiel M.J., Hendzel Z., Żylski W., *Modelowanie i sterowanie mobilnych robotów kołowych*, PWN, Warszawa 2013.
7. Byrski W., *Obserwacja i sterowanie w systemach dynamicznych*, UWND AGH, Kraków 2007.
8. Wiktorowicz K., *Sektorowo ograniczony uczący się rozmyty regulator stanu z modelem odniesienia*, XVII Krajowa Konferencja Automatyki 2011, Kielce-Cedzyna 2010, 470–480.
9. Wiktorowicz K., *Regulator rozmyty jako korektor nieliniowy*, „Pomiary Automatyka Kontrola” 58(3)/2012, 288–293.
10. Szabat K., *Model obserwatora stanu dla układu z nieliniowym wałem mechanicznym*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, nr 63, 355–368.
11. Jamoussi K. i in., *Robust Fuzzy Sliding Mode Observer for an Induction Motor*, “Journal of Electrical Engineering: Theory and Application”, Vol. 1, Issue 1, 2010, 42–51. DOI: 10.1109/SSD.2009.4956657. ■

Modeling of Two Rotor Aerodynamical System Using the Neuro-Fuzzy System

Abstract: The paper presents a proposal neurofuzzy model for complex nonlinear plant. Due to the peculiarities of analytical models, suggested fuzzy structure with adaptive selection of parameters. The concept of adaptive fuzzy observer, operating on the basis of created of neurofuzzy model. An evaluation of the effectiveness of the model and adaptive estimator in terms of the complexity of the design and computational effort has been made. Implementations of the model were carried out based on MATLAB environment tools.

Keywords: TRAS, Two Rotor Aerodynamical System, Neuro-Fuzzy System, state estimation, ANFIS

Artykuł recenzowany, nadesłany 30.01.2014 r., przyjęty do druku 11.04.2014 r.

mgr inż. Piotr Woźnica

Doktorant w Instytucie Automatyki i Informatyki Politechniki Opolskiej. Zainteresowania: metody sztucznej inteligencji w zastosowaniu do sterowania.

e-mail: pp.woznica@gmail.com

