

# Zastosowanie radialnej sieci neuronowej jako adaptacyjnego regulatora prędkości napędu dwumasowego

**Streszczenie.** Artykuł prezentuje zastosowanie sieci neuronowej adaptowanej on-line w pętli regulacji prędkości układu napędowego z połączeniem sprężystym. W algorytmie zastosowano model neuronowy z radialnymi funkcjami aktywacji. W celu aktualizacji wartości wag oraz centrów regulatora adaptacyjnego zastosowano algorytm gradientowy. W tej części obliczeń poprawki dla aktualnych parametrów regulatora neuronowego są mnożone przez stałe determinujące stopień oddziaływania zastosowanej metody adaptacji. Charakterystycznym rozwiązaniem, prezentowanym w niniejszym artykule, jest zastosowanie modelu rozmytego w celu wyznaczenia wspomnianych współczynników skalujących. Zaprojektowany regulator został przetestowany w symulacjach oraz wykonano badania eksperymentalne z wykorzystaniem procesora sygnałowego karty dSPACE1103. Uzyskane wyniki prezentują precyzję sterowania analizowanego regulatora neuronowego oraz jego odporność na zmiany parametrów obiektu.

**Abstract.** Article presents application of neural network trained on-line in speed control loop of electrical drive with elastic connection. In algorithm neural model with radial activation function was implemented. For updates of weights and centers of adaptive controller gradient method was used. In this part of calculations correction values for adaptive controller are calibrated. Specific solution, described in paper, is application of fuzzy model for determination of scaling coefficients. Designed controller was tested in simulations and then experiment was prepared (using dSPACE1103 card). Achieved results present high precision of control and also robustness against changes of the drive parameters. (*Application of radial basis function neural network for adaptive speed control of two-mass drive*).

**Słowa kluczowe:** radialna sieć neuronowa, adaptacja on-line, regulacja prędkości, napęd z połączeniem elastycznym.

**Keywords:** radial basis function neural network, on-line training, speed control, drive with elastic joint.

doi:10.12915/pe.2014.05.08

## Wstęp

W publikacji przedstawiono analizę działania układu regulacji prędkości napędu elektrycznego o złożonej części mechanicznej, zawierającej długi elastyczny wał, stanowiący połączenie silnika napędowego z maszyną roboczą. Występowanie drgań skrętnych takiego połączenia powoduje oscylacje zmiennych stanu, utrudniające precyzyjne sterowanie prędkością. Ponadto takie zakłócenia mogą być przyczyną uszkodzeń elementów łączących napędu oraz maszyn elektrycznych (np. sprzęgieł, łożysk).

W odniesieniu do układów z połączeniem elastycznym temat zastosowań sieci neuronowych w sterowaniu nie był zbyt często poruszany. Jedno z pierwszych zastosowań sieci neuronowej MLP oraz algorytmu wstecznej propagacji błędów przedstawiono w publikacji [1]. Badania symulacyjne dotyczyły sterowania sprzętem medycznym. Sieci neuronowe (SN) mogą również współpracować z liniowymi regulatorami. W układzie sterowania manipulatorem zastosowano dwie sieci neuronowe stanowiące kompensatory nieliniowości oraz zakłóceń [2]. Ponadto oryginalne rozwiązanie dotyczące implementacji neuronowego regulatora prędkości układu dwumasowego przedstawiono w [3]. Model układu został wykonany jako układ elektroniczny, zrealizowany w technice analogowej, a sieć neuronowa została zaimplementowana w komputerze PC.

Większość spotykanych rozwiązań dotyczy jednak zastosowań perceptronowych sieci neuronowych w estymacji zmiennych stanu (najczęściej prędkości obciążenia lub momentu skrętnego), przy czym jako regulator stosowany jest klasyczny regulator, regulator stanu lub ich kombinacje [4], [5]. Również modele sieci radialnej znajdują zastosowanie jako estymatory zmiennych stanu [6]. W pracy [7] przedstawiono analizę teoretyczną, dowód stabilności oraz badania symulacyjne struktury sterowania, w której regulator prędkości wykorzystuje obserwator zakłóceń realizowany za pomocą sieci RBF, w której adaptacji podlegały jedynie wagi modelu.

W niniejszym artykule, w strukturze sterowania prędkością napędu z połączeniem sprężystym zastosowano adaptacyjny regulator wykorzystujący sieć RBF. Parametry regulatora są dobierane on-line w trakcie działania napędu. W porównaniu do innych opisywanych rozwiązań, przyjęto, że regulator neuronowy wykorzystuje jedynie łatwo mierzalną zmienną stanu – prędkość silnika napędowego. W opisywanej aplikacji

sieci RBF aktualizacji podlegają jednocześnie wagi i centra funkcji radialnych. W tym celu zastosowano algorytm gradientowy, jako najefektywniejszy oraz najbardziej wrażliwy na zmiany sygnałów wejściowych [8], [9]. Istotną zaletą analizowanego regulatora jest występowanie jedynie dwóch parametrów dobieranych przez użytkownika. Pierwszy z nich dotyczy algorytmu adaptacji współczynników wagowych, drugi jest wykorzystywany w części związanej z aktualizacją centrów funkcji radialnych. Wartości obu parametrów treningowych wpływają bezpośrednio na dynamikę struktury sterowania. Współczynniki te są zależne od stałych czasowych układu dwumasowego, jednak ich wyznaczenie w sposób analityczny jest trudne. W tym celu zaproponowano model rozmyty wyznaczający on-line te współczynniki, zależnie od wartości błędów regulacji prędkości. Szczegóły dotyczące jego struktury zostały przedstawione w dalszej części artykułu.

Opisywany regulator został przetestowany w badaniach symulacyjnych, prezentujących dynamikę oraz precyzję sterowania, a także odporność na zmiany wybranych parametrów. Następnie algorytm sterowania zrealizowano w procesorze sygnałowym karty dSPACE 1103 w celu weryfikacji badań symulacyjnych w eksperymencie laboratoryjnym.

## Struktura sterowania oraz model matematyczny układu dwumasowego

Analizowany układ sterowania został oparty o klasyczną kaskadową strukturę. W zewnętrznej pętli sterowania prędkością zastosowano regulator neuronowy. Część elektromagnetyczna, odpowiadająca za kształtowanie momentu elektromagnetycznego została zamodelowana zgodnie z transmitancją:

$$(1) \quad G_e(s) = \frac{1}{T_{me}s + 1}$$

gdzie:  $T_{me}$  – stała czasowa obwodu kształtowania momentu elektromagnetycznego.

Opisane uproszczenie wprowadza pewien stopień uniwersalności uzyskiwanych wyników dla napędów z silnikami prądu stałego oraz indukcyjnymi.

Napęd z połączeniem sprężystym zamodelowano jako układ dwumasowy, w którym bezwładność silnika napędowego i maszyny obciążającej reprezentują odpowiednio stałe czasowe  $T_1$  i  $T_2$ . Wpływ elementu sprężystego (wału) jest opisany za pomocą członu całkującego o stałej czasowej  $T_c$ . Przy takich założeniach model matematyczny części mechanicznej napędu z połączeniem sprężystym można opisać za pomocą następujących równań (w wartościach względnych) [4], [6]:

$$(2) \quad T_1 \frac{d\omega_1(t)}{dt} = m_e(t) - m_s(t)$$

$$(3) \quad T_2 \frac{d\omega_2(t)}{dt} = m_s(t) - m_L(t)$$


$$(4) \quad T_c \frac{dm_s(t)}{dt} = \omega_1(t) - \omega_2(t),$$

gdzie:  $\omega_1$  – prędkość silnika,  $\omega_2$  – prędkość maszyny roboczej,  $m_s$  – moment skrętny,  $m_L$  – moment obciążenia,  $T_1$ ,  $T_2$ ,  $T_c$  – odpowiednio stałe czasowe mechaniczne silnika i maszyny roboczej oraz stała czasowa elementu sprężystego.

W rozważanym przypadku przyjęto następujące znamionowe wartości parametrów części mechanicznej:  $T_1=T_2=203\text{ms}$ ,  $T_c=1,2\text{ms}$ .

#### Adaptacyjny regulator prędkości z siecią RBF

Sieci neuronowe radialne należą, obok klasycznych sieci perceptronowych MLP, do najczęściej stosowanych modeli w rozwiązaniach technicznych. Jednak sieć RBF różni się od klasycznej sieci MLP strukturą, reprezentacją danych, a także metodami treningu [10], [11]. Struktura sieci RBF została przedstawiona na rysunku 1.



Rys. 1. Struktura sieci neuronowej RBF

Macierz radialnych funkcji aktywacji zastosowanych w neuronach warstwy ukrytej najczęściej wyznaczana jest z wykorzystaniem funkcji Gaussa:

$$(5) \quad f_g(\mathbf{X}, \mathbf{C}, \delta) = \exp\left(-\frac{\mathbf{v}^2}{\delta^2}\right),$$

gdzie:  $\delta$  jest parametrem skalującym, w rezultacie kształtującym funkcję radialną,  $\mathbf{v}$  prezentuje różnicę między centrum neuronu a wartościami wejściowymi (najczęściej norma Euklidesa),  $\mathbf{X}$  – wektor wejściowy sieci neuronowej,  $\mathbf{C}$  – macierz zawierająca centra sieci radialnej.

Obliczenia wartości wyjściowej sieci, opisuje wyrażenie:

$$(6) \quad y_i = b + \sum_{h=1}^h w_{hi} f_{g_h},$$

gdzie:  $h$  – liczba neuronów ukrytych,  $y_i$  – aktualna wartość  $i$ -tego wyjścia sieci neuronowej,  $w_{hi}$  – współczynnik wagowy pomiędzy  $h$ -tym neuronem ukrytym oraz  $i$ -tym wyjściem,  $b$  – bias.

W związku z powyższym wartość wyjściowa sieci neuronowej w zapisie macierzowym może być przedstawiona następująco:

$$(7) \quad y = b + \mathbf{W} \mathbf{f}_g(\mathbf{X}, \mathbf{C}, \delta).$$

Zgodnie z równaniem (7), o sygnale wyjściowym sieci neuronowej RBF decydują w znaczącym stopniu wartości elementów macierzy  $\mathbf{W}$  oraz  $\mathbf{C}$ . Optymalizacja tych parametrów umożliwia minimalizację funkcji celu, która w ogólnym przypadku opisuje zbieżność aktualnych sygnałów wyjściowych SN oraz pożądanej trajektorii  $d$ . W opisywanej aplikacji sieci RBF, aktualizacji podlegają jednocześnie wagi i centra funkcji radialnych. W tym celu zastosowano algorytm gradientowy, którego obliczenia są realizowane *on-line* w trakcie pracy układu napędowego. Współczynniki wagowe macierzy  $\mathbf{W}$  podlegały adaptacji w celu minimalizacji funkcji celu  $E$  zgodnie z poniższym równaniem [12]:

$$(8) \quad \mathbf{W}(k) = \mathbf{W}(k-1) - \eta_w \frac{\partial E^2}{\partial \mathbf{W}}.$$

Postępując według algorytmu gradientowego zależność opisująca adaptację macierzy  $\mathbf{C}$ :

$$(9) \quad \mathbf{C}(k) = \mathbf{C}(k-1) - \eta_c \frac{\partial E^2}{\partial \mathbf{C}}.$$


Współczynniki  $\eta_w$  oraz  $\eta_c$  są stałymi determinującymi szybkość działania algorytmu. Opracowanie wzorów analitycznych opisujących zależność tych współczynników algorytmu adaptacyjnego sieci neuronowej od parametrów obiektu jest kłopotliwe, poza tym obowiązuje tylko dla danych wartości stałych czasowych napędu. W związku z tym zaproponowano uzależnienie tych parametrów regulatora neuronowego od aktualnej wartości błędu regulacji prędkości oraz jego zmiany. W sytuacji kiedy błąd wzrasta, w celu jego zniwelowania, wartości omawianych parametrów regulatora powinny być zwiększane (jednocześnie wzrasta jego dynamika), w stanach ustalonych ich poziom zmniejszono (zakłócenia pomiarowe, oscylacje nie podlegają wzmocnianiu).

Adaptacyjna zmiana parametrów  $\eta_w$  oraz  $\eta_c$ , w trakcie pracy napędu, może zostać zrealizowana poprzez zastosowanie modelu rozmytego. Wartość bezwzględna uchybu regulacji prędkości  $e$  oraz jej pochodna  $de$  stanowią sygnały wejściowe modelu rozmytego. Zastosowano trójkątne symetryczne wejściowe funkcje przynależności modelu rozmytego. Ich rozmieszczenie jest związane z zakresem zmian sygnałów wejściowych. Do utworzenia bazy reguł wykorzystano założenia przedstawione powyżej. W bloku defuzyfikacji zastosowano metodę wysokości (singletonów).


Opisywany regulator prędkości nie posiada jawnych elementów całkujących w torze głównym przetwarzania. Jednak astatyzm regulacji prędkości jest zapewniony, poprzez sumowanie (całkowanie) wartości aktualnych oraz aktualizacji dla wartości wag oraz centrów, w części adaptacyjnej. W wektorze wejściowym  $\mathbf{X}$  sieci RBF zastosowano: błąd oraz jego wartość z poprzedniej iteracji.

## Wyniki badań

Model opisanej struktury sterowania został zrealizowany i przetestowany w programie Matlab/Simulink. Celem badań było między innymi zaprezentowanie wpływu parametrów  $\eta_c$  oraz  $\eta_w$  regulatora neuronowego na działanie układu napędowego. Na rysunku 2 przedstawiono przebiegi zmiennych stanu napędu dla różnych wartości współczynników treningowych. Zmiany każdego z parametrów testowano dla stałej wartości drugiego z nich, równej 0,01. Oba parametry wpływają na właściwości dynamiczne układu. Wraz ze wzrostem wartości  $\eta_c$  lub  $\eta_w$  zwiększa się dynamika zmiennych stanu napędu dwumasowego: czasy ustalania na zadanym poziomie są krótsze, jednocześnie reakcja układu regulacji na załączenie obciążenia jest szybsza.



Rys.2. Przebiegi prędkości silnika (a,c) i obciążenia (b,d) dla różnych wartości współczynników algorytmów adaptacyjnych neuronowego regulatora prędkości




Rys.3. Przebiegi prędkości silnika i maszyny roboczej dla:  $\eta_w=0,0001$  (a) oraz  $\eta_w=0,3$  (b) – przypadki szczególne

W zaprezentowanym zakresie wartości  $\eta_c$  lub  $\eta_w$  napęd działa poprawnie, zmienia się jedynie czas odpowiedzi. Należy zaznaczyć, że dobór tych parametrów jest szczególnie istotny w przypadku napędu dwumasowego. Dla pewnych wartości parametrów algorytmu adaptacyjnego, niekontrolowane bezpośrednio zmienne stanu napędu (moment skrętny i prędkość obciążenia) mogą powodować oscylacje, które nie będą skutecznie tłumione. Ekstremalne przypadki zobrazowano na rysunku 3. Badano wpływ bardziej istotnego z parametrów -  $\eta_w$ . Zbyt mała wartość przyjmowana w testach wpływa na zdecydowanie zbyt wolne działanie napędu. Poza tym przy wolnym układzie regulacji dynamiczne załączenie obciążenia jest również zakłóceniem wywołującym oscylacje. Próba bardzo szybkiego wymuszenia prędkości zadanej prowadzi także do wzbudzenia niedopuszczalnych zakłóceń. Takie


działanie napędu, poza brakiem precyzji sterowania, może prowadzić do utraty stabilności oraz uszkodzeń elementów łączących.

W artykule zaproponowano adaptację współczynników treningowych sieci RBF za pomocą modelu rozmytego. W związku z tym, że dla podobnych wartości  $\eta_c$  oraz  $\eta_w$  napęd działa poprawnie, założono ich równą wartość ( $\eta_c = \eta_w = \eta_{fuzzy}$ ). Uzyskane wyniki pokazano na rysunku 4.

Układ napędowy z neuronowym regulatorem prędkości RBF, z adaptacyjnymi parametrami algorytmu gradientowego, umożliwił ustalanie się prędkości silnika oraz maszyny roboczej na zadanym poziomie w bardzo krótkim czasie.




Rys.4. Przebiegi zmiennych stanu struktury sterowania: prędkości silnika oraz obciążenia (a), momentu elektromagnetycznego (b) oraz współczynnika  $\eta_{fuzzy}$  (c) dla znamionowych parametrów napędu




Rys.5. Przebiegi zmiennych stanu struktury sterowania: prędkości silnika oraz obciążenia (a,c,e), momentu elektromagnetycznego (b,d,f) dla różnych wartości mechanicznej stałej czasowej obciążenia  $T_2$

W kolejnych badaniach testowano wpływ zmian stałych czasowych:  $T_2$ ,  $T_c$  oraz  $T_{me}$  (poza testami prezentującymi wpływ opóźnień pętli kształtowania momentu elektromagnetycznego przyjęto  $T_{me}=0$ ), na działanie układu regulacji. Na rysunkach 5-7 przedstawiono uzyskane przebiegi zmiennych stanu napędu dla zmian wymienionych parametrów napędu. W badanym zakresie zmian parametrów adaptacyjny regulator neuronowy zapewnia odporne sterowanie prędkością układu dwumasowego.


Następnie analizowana struktura sterowania została zaimplementowana w procesorze sygnałowym karty dSPACE1103 oraz przetestowana na stanowisku laboratoryjnym, którego szczegółowy opis przedstawiono w pracy [4]. Przebiegi badań eksperymentalnych przedstawione na rysunku 8, prezentują dobre właściwości dynamiczne napędu z adaptacyjnym neuronowym regulatorem prędkości.



Rys.6. Przebiegi zmiennych stanu struktury sterowania: prędkości silnika oraz obciążenia (a,c,e), momentu elektromagnetycznego (b,d,f) dla różnych wartości mechanicznej stałej czasowej obciążenia  $T_c$



Rys.7. Przebiegi zmiennych stanu struktury sterowania: prędkości silnika oraz obciążenia (a), momentu silnika (b) dla zwiększonej wartości stałej czasowej obwodu elektromagnetycznego  $T_{me}$



Rys.8. Przebiegi prędkości: silnika i obciążenia (a), momentu elektromagnetycznego (b) oraz parametru  $\eta_{fuzzy}$  (c) – badania eksperymentalne

Układ napędowy szybko reaguje na wymuszenia zewnętrzne (obciążenie). Model rozmyty, adaptujący parametry algorytmów gradientowych, poprawnie steruje

dynamiką układu sterowania, możliwe jest zaobserwowanie reakcji tego elementu regulatora neuronowego w trakcie szybkich zmian prędkości napędu oraz przełączeń momentu obciążenia.

## Podsumowanie

W artykule opisano neuronowy regulator prędkości napędu z połączeniem sprężystym wykorzystujący sieć neuronową o radialnych funkcjach bazowych. Współczynniki wagowe oraz centra sieci neuronowej dobierane są *on-line*. Ponadto, zaproponowano model rozmyty sterujący właściwościami dynamicznymi adaptacji parametrów sieci. Należy podkreślić, że implementacja modelu rozmytego w sterowaniu wartością współczynników algorytmu adaptacji stanowi rozwiązanie oryginalne dla istotnego problemu pojawiającego się w procesie projektowania regulatorów neuronowych bazujących na różnych typach sieci. Zaprezentowane wyniki badań przedstawiają precyzję sterowania oraz odporność na zmiany parametrów układu dwumasowego. Implementacja sprzętowa regulatora neuronowego nie jest skomplikowana. Adaptacja parametrów regulatora umożliwia uzyskanie bardzo dobrego działania napędu, bez dodatkowego strojenia parametrów.

Dodatkową zaletą proponowanego regulatora neuronowego jest możliwość jego zaprojektowania, w sposób analogiczny do przedstawionego, dla układów napędowych z połączeniem sztywnym oraz różnymi typami silników.

Praca finansowana przez Narodowe Centrum Nauki w ramach projektu UMO-2011/01/B/ST/7/04632 (2011-2014).

## LITERATURA

- [1] Englert M., Trapp R., de Klerk R., Neural Control of a Nonlinear Elastic Two-Mass System, *Int. Conf. Computational Intelligence, Theory and Applications*, 1226 (1997), 553-553
- [2] Zhihong Su, Khorasani K., A Neural-Network-Based Controller for a Single-Link Flexible Manipulator Using the Inverse Dynamics Approach, *IEEE Trans. Ind. Electronics*, 48 (2001), 6, 1074-1086
- [3] Dhaoui R., Nouri K., Neural Network-Based Speed Control of A Two-Mass-Model System, *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 3. 5 (1999), 427-430
- [4] Orłowska-Kowalska T., Szabat K., Neural-Network Application for Mechanical Variables Estimation of a Two-Mass Drive System, *IEEE Trans. Industrial Electronics*, 54 (2007), 3, 1352-1364
- [5] Joong-Ho Song, Kyo-Beum Lee, Ick Choy, Kwang-Bae Kim, Joo-Yeop Choi, Kwang-Won Lee, Vibration control of 2-mass system using a neural network torsional torque estimator, *Proc. 24th Ann. Conf. IECON '98*, 3 (1998), 1785- 1788
- [6] Orłowska-Kowalska T., Kaminski M., Application of MLP and RBF neural networks in the control structure of the drive system with elastic joint, *COMPEL*: 28, 3 (2009), 556-569
- [7] Lee K.-B., Blaabjerg F., An Improvement of Speed Control Performances of a Two-Mass System using a Universal Approximator, *Electrical Engineering*, 89 (2007), 5, 389-396
- [8] Wenyu Sun, Ya-xiang Yuan, *Optimization Theory and Methods: Nonlinear Programming*, Springer; 1 ed. (2006)
- [9] Narendra K.S., Parthasarathy K., Gradient Methods for the Optimization of Dynamical Systems Containing Neural Networks, *IEEE Trans. Neural Networks*, 2, 2 (1991), 252-262
- [10] Bishop M.C., *Neural Networks for Pattern Recognition*, Oxford University Press, (1996)
- [11] Yu H., Xie T., Paszczynski S., Wilamowski B.M., Advantages of Radial Basis Function Networks for Dynamic System Design, *IEEE Trans. Industrial Electronics*, 58 (2011), 12, 5438-5450
- [12] Farrag M. E. A., Putrus G. A., An on-line training radial basis function neural network for optimum operation of the UPFC, *European Transactions on Electrical Power*, 21 (2011), 1, 27-39

## Autorzy:

dr inż. Marcin Kamiński, prof. dr hab. inż. Teresa Orłowska-Kowalska, Politechnika Wrocławska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, E-mail: [marcin.kaminski@pwr.wroc.pl](mailto:marcin.kaminski@pwr.wroc.pl), [teresa.orlowska-kowalska@pwr.wroc.pl](mailto:teresa.orlowska-kowalska@pwr.wroc.pl)