

## Regulatory neuronowe trenowane *off-line* zastosowane w strukturze sterowania prędkością napędu dwumasowego

**Streszczenie.** W artykule przedstawiono analizę działania neuronowych regulatorów prędkości trenowanych *off-line*, zaimplementowanych w układzie napędowym z połączeniem elastycznym. Testom poddano sterowanie z modelem odwrotnym (*Direct Inverse Control*) oraz sterowanie z modelem wewnętrznym (*Internal Model Control*). Istotnym założeniem prowadzonych badań był brak adaptacji modeli neuronowych w trakcie działania struktury sterowania. Zaprezentowano wyniki badań symulacyjnych oraz eksperymentalnych zrealizowanych dla znamionowych oraz zmienionych parametrów obiektu.

**Abstract.** In this paper analysis of neural speed controllers implemented in electrical drive with elastic connection is presented. Two control structures were tested: *Direct Inverse Control* and *Internal Model Control*. Important assumption in described application is lack of weights adaptation during work of the drive. Simulations and experimental tests prepared for nominal and changed values of parameters are shown. (**Neural controllers trained *off-line* applied in speed control structure of two-mass drive.**)

**Słowa kluczowe:** regulator neuronowy, sterowanie z modelem odwrotnym, sterowanie z modelem wewnętrznym, układ dwumasowy.

**Keywords:** neural controller, direct inverse control, internal model control, two-mass system.

### Wstęp

Modelowanie neuronowe jest metodą projektowania struktury typu black-box, która umożliwia reprezentację systemów lub procesów trudnych do opisanego za pomocą klasycznych metod matematycznych. Identyfikacja rzeczywistego obiektu w wielu przypadkach jest trudna do wykonania. W wymienionych sytuacjach korzystne jest zastosowanie metod sztucznej inteligencji do reprezentacji rzeczywistego zjawiska [1].

Modele neuronowe są często stosowane w wielu zadaniach związanych z napędami elektrycznymi, np. są implementowane jako: regulatory [2]-[4] lub estymatory zmiennych stanu [5], detektory uszkodzeń [6], itp.

Poprawna realizacja zadania przez sieć neuronową zależy głównie od odpowiedniej adaptacji współczynników wagowych. Poprawka tych parametrów może być obliczana oraz wprowadzana do modelu, równoległe do działania sieci neuronowej w strukturze napędowej. W takim przypadku, w każdej iteracji obliczeń całej struktury wyznaczany jest błąd (zgodnie ze spełnianym zadaniem, np. błąd regulacji), informacja o tej wartości oraz aktualnym stanie modelu neuronowego wprowadzana jest do algorytmu adaptacji, po czym obliczane są korekty dla współczynników wagowych. Zatem opisana adaptacja, ze względu na sposób realizowanych obliczeń wykonywana jest *on-line* [7]. Drugim sposobem jest trening sieci neuronowej w trybie *off-line*. Tego typu założenie wymaga opracowania zestawu danych wykorzystywanych w treningu (ewentualnie dodatkowo zbiór walidacyjny), po czym realizowane są obliczenia algorytmu adaptacji wag modelu neuronowego, następnie opracowany model aplikowany jest w strukturze sterowania.

W badaniach układów regulacji napędu elektrycznego z połączeniem elastycznym, opisanych w artykule testowano dwie struktury: wykorzystujące model odwrotny obiektu – *Direct Inverse Control*, oraz sterowanie z modelem wewnętrznym – *Internal Model Control* [1]. Tego typu układy regulacji aplikowane są w napędach elektrycznych z silnikami prądu stałego [8], [9] oraz indukcyjnymi [4], [9]-[11].

W niniejszym artykule, inaczej niż w poprzednich pracach autorów (np. [12]-[14]) analizowane są wyłącznie neuroregulatory trenowane *off-line*. Zatem jednym z najistotniejszych warunków działania badanych regulatorów był brak adaptacji współczynników wagowych modelu neuronowego w trakcie testów układu napędowego. Dla badanych struktur przedstawiono wyniki testów symulacyjnych zrealizowanych w programie Matlab-Simulink oraz rezultaty

badań eksperymentalnych wykonanych na stanowisku laboratoryjnym z wykorzystaniem karty dSPACE1103.

### Model matematyczny sterowanego obiektu

Regulatory neuronowe trenowane *off-line* zastosowano w napędzie elektrycznym z połączeniem sprężystym. Podstawą dla rozważanego układu regulacji jest klasyczna kaskadowa struktura sterowania [12]. Badane neuroregulatory włączano w zewnętrznej pętli regulacji prędkości. Wewnętrzna pętla regulacji momentu (prądu) silnika została zamodelowana w postaci uproszczonej, za pomocą transmitancji:

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

gdzie:  $T_{me}$  – stała czasowa obwodu kształtowania momentu elektromagnetycznego (przyjmowana w zakresie (0÷5)ms).

Model matematyczny układu z połączeniem sprężystym (układu dwumasowego), stosowany w badaniach symulacyjnych, opisany jest za pomocą następujących równań (przyjęto wartości względne zmiennych stanu) [12], [13]:

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

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

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

gdzie:  $\omega_1$  – prędkość silnika,  $\omega_2$  – prędkość maszyny roboczej,  $m_s$  – moment skrętny,  $m_L$  – moment obciążenia,  $T_1$  – mechaniczna stała czasowa silnika,  $T_2$  – mechaniczna stała czasowa obciążenia,  $T_c$  – stała czasowa elementu sprężystego.

### Sterowanie z modelem odwrotnym (*Direct Inverse Control*)

Pierwszą z badanych struktur układu dwumasowego z neuroregulatorem prędkości trenowanym *off-line* jest struktura, w której zaimplementowano neuronowy model odwrotny. W teorii sterowania często opisywane są zastosowania neuronowego modelu odwrotnego sterowanego procesu [1]. Zakładając, że proces dynamiczny może być opisany za pomocą równania:

$$(5) y(k+1) = f(y(k), \dots, y(k-n+1), u(k), \dots, u(k-m+1)),$$

gdzie:  $y$  – wyjście obiektu sterowanego,  $u$  – sygnał wejściowy obiektu,  $n$  – liczba wyjść,  $m$  – liczba wejść.


Model odwrotny obiektu (5) może być opisany równaniem:

$$(6) \hat{u}(k) = \hat{f}^{-1}(y(k+1), y(k), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)).$$

W celu realizacji modelu odwrotnego zastosowano sieć neuronową. Neuronowy model odwrotny może być zastosowany jako regulator, jeśli wprowadzona zostanie korekta w równaniu (6), polegająca na zamianie wartości wyjściowej  $y(k+1)$  na wartość zadaną  $r(k+1)$ :

$$(7) \hat{u}(k) = \hat{f}^{-1}(r(k+1), y(k), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)).$$


Schemat opisywanej struktury sterowania przedstawiono na rys. 1 (gdzie  $z^{-1}$  symbolizuje opóźnienia sygnałów. W odniesieniu do analizowanego układu napędowego z połączeniem elastycznym, sygnałem zadanym  $r$  jest założona wartość prędkości  $\omega_{ref}$ , natomiast jako wyjście obiektu przyjęto prędkość silnika  $\omega_l$ .



Rys. 1. Sterowanie z modelem odwrotnym

W procesie opracowywania neuronowego modelu odwrotnego stosowane są dwie metody: trening ogólny (*general training*) oraz trening specjalizowany (*specialized training*). Ogólną zasadę pierwszej z nich przedstawia rysunek 2. Generowana trajektoria zadana  $x$  podawana jest na wejście obiektu. Uzyskany sygnał wyjściowy  $y$  stanowi sygnał wejściowy projektowanej sieci neuronowej. W procesie treningu założonymi próbkami wyjściowymi są dane pobudzające układ  $x$ . Ogólnie można zapisać, że w trakcie działania algorytmu optymalizacyjnego minimalizowany jest błąd:

$$(8) J_1(w) = \sum_{k=1}^N (x - x_n)^2.$$




Rys. 2. Schemat obliczeń dla modelu neuronowego odwrotnego – trening ogólny

Następnym układem regulacji neuronowej testowanym dla napędu z połączeniem sprężystym jest układ z modelem odwrotnym, dla którego zastosowano trening specjalizowany. W tym przypadku model odwrotny jest realizowany według schematu przedstawionego na rys. 3. W tej metodzie opracowywania regulatora neuronowego, trenowana sieć

bezpośrednio wpływa na działanie obiektu. Wyjście modelu neuronowego jest sygnałem wejściowym obiektu. Sygnał zadany  $r$  porównywany jest z wartością wyjściową obiektu  $y$ , uzyskany w ten sposób błąd jest stosowany do korekty wag neuroregulatora w procesie treningu (oznaczenia we wzorze (9) odpowiadają rysunkowi 3):


$$(9) J_2(w) = \sum_{k=1}^N (r - y)^2.$$



Rys. 3. Schemat obliczeń dla modelu neuronowego odwrotnego – trening specjalizowany

### Sterowanie z modelem wewnętrznym (*Internal Model Control*)

Sterowanie z modelem wewnętrznym stanowi kombinację działania dwóch modeli neuronowych. Pierwszy z nich jest opracowany jako model odwrotny, drugi jako model dokładny obiektu [15].



Rys. 4. Zmodyfikowana-uproszczona struktura sterowania z modelem wewnętrznym

Jednak zastosowanie dwóch modeli neuronowych, trenowanych *off-line*, istotnie komplikuje proces projektowania i zwiększa złożoność obliczeniową algorytmu. W celu uproszczenia struktury sterowania wprowadzono strukturę zmodyfikowaną (rys. 4). W układzie regulacji usunięto sieć neuronową symulującą obiekt, natomiast wprowadzono dodatkowy model odniesienia [16]. W porównaniu z klasycznym układem z modelem odwrotnym, w testowanej strukturze uchyb regulacji, na podstawie którego regulator neuronowy generuje sygnał sterujący, jest uzyskiwany poprzez porównanie wartości sterowanej zmiennej stanu z sygnałem z modelu odniesienia, który opisany jest wzorem:


$$(10) G_r(s) = \frac{\omega_0^2}{s^2 + 2\zeta\omega_0 s + \omega_0^2},$$

gdzie:  $\zeta$  jest założonym współczynnikiem tłumienia, natomiast  $\omega_0$  zadana częstotliwość rezonansowa. We wszystkich dalszych testach badanego układu napędowego (symulacyjnych oraz eksperymentalnych) przyjęto:  $\zeta = 0,8$  oraz  $\omega_0 = 30$  (poza przykładem prezentującym wpływ tych parametrów). W opisywanym układzie regulacji uwzględnione, a następnie korygowane są dodatkowe zakłócenia wprowadzane do obiektu. Model odwrotny opracowano zgodnie z metodą przedstawioną na rys. 3.

## Wyniki badań symulacyjnych


Symulacje wykonano w programie Matlab z wykorzystaniem modelowania graficznego w programie Simulink. Testy numeryczne realizowano z krokiem obliczeniowym  $\Delta T=0,1\text{ms}$ . W badanym napędzie przyjęto następujące wartości parametrów części mechanicznej (zgodne ze stanowiskiem laboratoryjnym):  $T_1=T_2=203\text{ms}$  oraz  $T_c=1,2\text{ms}$ . W obliczeniach założono następującą strukturę sieci neuronowej:  $\{lwej-5-1\}$ , przyjęto  $lwej$  wejść, pięć neuronów warstwy ukrytej oraz jedno wyjście. W warstwie ukrytej wprowadzono sigmoidalne funkcje aktywacji, neuron wyjściowy zawierał funkcję liniową. W treningu przedstawionym na rysunku 2 zastosowano  $lwej=5$  wejść. Liczba wejść sieci neuronowej zastosowanej w treningu *specialized training* wynosiła  $lwej=2$ . W obu metodach treningu (rys.2 oraz rys.3) w wektorze wejściowym wprowadzano dodatkowe próbki historyczne sygnałów wejściowych.

Pierwszą testowaną strukturą był układ *Direct Inverse Control*, w którym sieć neuronową opracowano zgodnie z metodą *general training*. Przebiegi zmiennych stanu napędu w odpowiedzi na skokową zmianę prędkości zadanej przedstawiono na rysunku 5. Założono prędkość równą 25% wartości znamionowej. W chwili  $t=2\text{s}$  załączony został znamionowy moment obciążenia. Napęd dynamicznie reaguje na zmiany sygnałów zadanych. Jednak prędkość nie jest ustawiana precyzyjnie na wartości zadanej, widoczne są oscylacje zmiennych stanu. Dodatkową istotną wadą układu jest występowanie uchybu ustalonego prędkości po załączeniu momentu obciążenia.



Rys.5. Przebiegi prędkości silnika  $\omega_1$  i maszyny roboczej  $\omega_2$ , oraz momentu elektromagnetycznego  $m_e$ ; odpowiedź układu na skokową zmianę prędkości zadanej – *Direct Inverse Control (general training)*

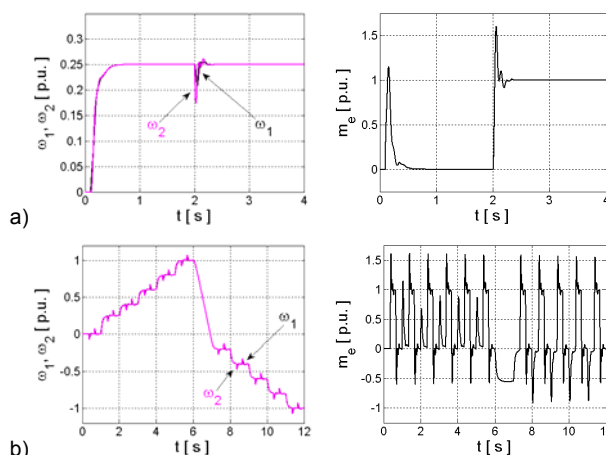
Następnie badaniom poddano układ *Direct Inverse Control*, dla którego regulator neuronowy został zaprojektowany zgodnie z metodą *specialized training*. Rezultaty badań symulacyjnych zaprezentowano na rysunku 6. Uzyskano właściwości struktury sterowania bardzo podobne do poprzedniego przypadku. Wylimitowanie błędów regulacji w testowanej strukturze sterowania było niemożliwe, układ nie działał poprawnie.




Rys.6. Przebiegi prędkości  $\omega_1$ ,  $\omega_2$ , oraz momentu elektromagnetycznego  $m_e$ , odpowiedź układu na skokową zmianę prędkości zadanej – *Direct Inverse Control (specialized training)*

Wyniki badań symulacyjnych dla kolejnej struktury sterowania – *Internal Model Control* zaprezentowano na rysunku 7. Testy wykonano dla skokowej zmiany prędkości zadanej oraz w przypadku szerokiego zakresu zmian sygnału

wymuszającego. W tym przypadku działa poprawnie, wylimitowane zostały problemy zaobserwowane w strukturze sterowania z modelem odwrotnym (brak uchybu ustalonego w układzie, zatem nie istnieje konieczność wprowadzania dodatkowego całkowania w algorytmie regulatora). Przebiegi przedstawione w poprzedniej części artykułu wykonano przy założeniu idealnej (bezwłódczej) pętli kształtowania momentu elektromagnetycznego ( $T_{me}=0\text{s}$ ). Na rys. 8 przedstawiono rezultaty testów dla  $T_{me}=5\text{ms}$ . Również w tym przypadku układ działa poprawnie, a uzyskane przebiegi niewiele różnią się od pokazanych na rys. 7a. Wartość kryterium *Integral Absolute Error* wynosiła odpowiednio: dla idealnej pętli kształtowania momentu elektromagnetycznego –  $IAE=0,0284$ , natomiast po wprowadzeniu opóźnienia w pętli momentowej –  $IAE=0,0287$ .



Rys.7. Przebiegi prędkości  $\omega_1$ ,  $\omega_2$  i momentu elektromagnetycznego  $m_e$  – *Internal Model Control (specialized training)*



Rys.8. Przebiegi prędkości  $\omega_1$ ,  $\omega_2$  i momentu elektromagnetycznego  $m_e$  dla zwiększonej wartości stałej czasowej obwodu kształtowania momentu elektromagnetycznego  $T_{me} = 5\text{ms}$  – *Internal Model Control (specialized training)*


## Badania eksperymentalne

W celu weryfikacji uzyskanych wyników symulacyjnych algorytm sterowania z regulatorem neuronowym zaimplementowano w procesorze sygnałowym karty dSPACE1103. Kod kompilowano bezpośrednio w programie Matlab/Simulink. Obliczenia zrealizowano z próbkowaniem identycznym jak przyjęty w badaniach symulacyjnych. Szczegóły konstrukcyjne zestawu laboratoryjnego przedstawiono w [14].


W eksperymencie testowano jedynie układ regulacji *Internal Model Control*, dla którego uzyskano najlepsze wyniki w badaniach symulacyjnych. Wyniki przedstawiono na rysunkach 9-10. Wstępnie analizowano działanie układu regulacji przy znamionowych parametrach napędu (rys.9a). Otrzymane przebiegi potwierdzają właściwości uzyskane w symulacjach. W kolejnych testach (rys.9b) na wale silnika obciążającego zamontowano dodatkową tarczę w celu zmiany momentu bezwładności. Nieznaczną różnicę trajektorii obu prędkości zaobserwowano w trakcie rozruchu napędu z dwukrotnie zwiększoną wartością mechaniczną

stałej czasowej obciążenia  $T_2$ . Moment elektromagnetyczny wymuszany w trakcie rozruchu jest również większy w tym przypadku.

Na rysunku 10 przedstawiono wyniki badań eksperymentalnych wykonanych dla różnych wartości parametrów modelu odniesienia. W badanym zakresie zmian tych parametrów uzyskano podobne przebiegi zmiennych stanu układu dwumasowego.



Rys.9. Przebiegi prędkości:  $\omega_1$ ,  $\omega_2$  i momentu elektromagnetycznego  $m_e$  dla znamionowych parametrów obiektu (a) oraz dla zwiększonej wartości stałej czasowej  $T_2 = 2T_{2N}$  (b) – badania eksperymentalne



Rys.10. Przebiegi prędkości:  $\omega_1$ ,  $\omega_2$  i momentu elektromagnetycznego  $m_e$  dla znamionowych parametrów obiektu; wpływ parametrów modelu odniesienia: a –  $\zeta=0,8$  oraz  $\omega_0=50$ , b –  $\zeta=0,5$  oraz  $\omega_0=30$ .

## Podsumowanie

W artykule przedstawiono wyniki badań symulacyjnych oraz eksperymentalnych neuronowych modeli trenowanych *off-line*, zastosowanych w układzie regulacji prędkości napędu elektrycznego z połączeniem sprzężystym. Na podstawie przeprowadzonych badań oraz uzyskanych wyników testów można sformułować następujące wnioski.

- > Badania wykazują, że w układzie sterowania z modelem odwrotnym (w obu metodach treningu: *specialized training* oraz *general training*) dla układu dwumasowego, zapewnienie utrzymania prędkości napędu na poziomie zadanym po załączeniu obciążenia jest kłopotliwe.
- > Bardzo dobre wyniki testów uzyskano dla układu sterowania z modelem wewnętrznym (*Internal Model Control*). Istotnym założeniem, zdecydowane upraszczającym proces projektowania jest wprowadzenie modelu odniesienia zamiast drugiej sieci neuronowej w strukturze regulatora

prędkości. Zaletą regulatora *Internal Model Control* jest skuteczne przeciwdziałanie występowaniu błędów związanego z załączeniem obciążenia, bez wprowadzania do regulatora dodatkowego członu całkującego.

- > Uzyskano bardzo dobre sterowanie prędkością obciążenia, pomimo braku sprzężeń zwrotnych od prędkości  $\omega_2$  lub momentu skrętnego  $m_s$ .
- > Realizacja praktyczna regulatorów neuronowych trenowanych *off-line* wymaga mniejszej mocy obliczeniowej w porównaniu z regulatorami z adaptacją realizowaną *on-line*.
- > Proponowane algorytmy sterowania mogą być stosowane w praktyce przy wykorzystaniu różnych typów dostępnych układów programowalnych: procesorów sygnałowych (stała lub zmiennoprzecinkowych) lub matrycy FPGA.

Praca finansowana przez Narodowe Centrum Nauki w ramach projektu UMO-2011/01/B/ST7/04632 (2011-2014).

## LITERATURA

- [1] Norgaard M., Ravn O., Poulsen N.K., Hansen L.K., *Networks for Modelling and Control of Dynamic Systems*, Springer, 2003.
- [2] Pajchrowski T., Zawirski K., Application of Artificial Neural Network to Robust Speed Control of Servodrive, *IEEE Trans. on Industrial Electronics*, 54 (2007), n. 1, 200-207.
- [3] Grzesiak L.M., Megnack V., Sobolewski J., Ufnalski B., Genetic Algorithm for Parameters Optimization of ANN-based Speed Controller, *Proc. Int. Conf. EUROCON (2007)*, 1700 - 1705.
- [4] Grzesiak L.M., Wyszomierski D., Sterowanie adaptacyjne napędem prądu przemiennego w układzie z modelem odniesienia i neuronowym regulatorem prędkości obrotowej, *Przegląd Elektrotechniczny*, 80 (2004), n. 1, 11-16.
- [5] Sperb E.C.L., Negri L.H., et. al., Sensorless control of PMSM using a new efficient neural network speed estimator, *Int. Conf. Power Engineering, Energy and Electrical Drives (POWERENG)*, (2011), 1–5.
- [6] Kowalski C.T., Orłowska-Kowalska T., Neural networks application for induction motor faults diagnosis, *Mathematics and Computers in Simulation*, 63 (2003), n. 3-5, 435 - 448
- [7] Saad D., *On-Line Learning in Neural Networks*, Cambridge University Press, 2009.
- [8] Hashmia A.L., Dakheel SH., Speed Control of Separately Exited DC Motor Using Artificial Neural Network, *Journal of Engineering and Development*, 16 (2012), n. 4, 349-362.
- [9] Rai N., Rai B., Neural Network based Closed loop Speed Control of DC Motor using Arduino Uno, *International Journal of Engineering Trends and Technology*, 4 (2013), n. 2, 137-140.
- [10] Girovsky P., Neurocontroller for Induction Motor, *Elektroenergetika*, 6 (2013), n. 1, 15-18.
- [11] Venkatesan J., Rama Reddy S., Neural Network Controlled Energy Saver for Induction Motor Drive, *Journal of Industrial Technology*, 26 (2010), n. 1, 2-10.
- [12] Kamiński M., Orłowska-Kowalska T., Adaptive neural speed control of the induction motor drive, *Przegląd Elektrotechniczny*, 89 (2013), n. 2a, 21-24
- [13] Kamiński M., Orłowska-Kowalska T., Analiza porównawcza wybranych neuroregulatorów prędkości dla napędu z połączeniem sprzężystym – opis modeli neuronowych, *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych, ser. Studia i Materiały*, 33 (2013) 3-13
- [14] Kamiński M., Orłowska-Kowalska T., Analiza porównawcza wybranych neuroregulatorów prędkości dla napędu z połączeniem sprzężystym – wyniki badań, *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych, ser. Studia i Materiały*, 33 (2013) 14-29
- [15] Hunt K.J., Sbarbaro D., Neural Networks for Nonlinear Internal Model Control, *IEE Proceedings*, 138 (1991), n. 5, 431-438.
- [16] Rivals I., Personnaz L., Nonlinear internal model control using neural networks: application to processes with delay and design issues, *IEEE Trans. Neural Networks*, 11 (2000), n. 1, 80 - 90.

**Autorzy:** dr inż. Marcin Kamiński, prof. dr hab. inż. Teresa Orłowska-Kowalska, Politechnika Wroclawska, Katedra Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, E-mail: marcin.kaminski@pwr.wroc.pl, teresa.orlowska-kowalska@pwr.wroc.pl