

Zastosowanie sterowania z modelem wewnętrznym opartego o sieci neuronowe dla napędu z elastycznym sprzęgłem

Streszczenie. W artykule opisano sterowanie układem napędowym z połączeniem sprężystym, pętla regulacji prędkości została zaprojektowana w oparciu o dwa modele neuronowe. Jeden z nich stanowi główny regulator, natomiast drugi jest modelem odniesienia wykorzystywanym w trakcie obliczeń. Adaptacja wag sieci neuronowych jest realizowana on-line. Artykuł zawiera opis teoretyczny zaimplementowanej struktury, a także badania symulacyjne oraz eksperymentalne zrealizowane z wykorzystaniem procesora sygnałowego karty dSPACE1103.

Abstract. Paper presents control system applied for electrical drive with elastic connections. Speed control loop of the whole structure is based on two neural models. One of them is applied as the main controller, the second is the internal model of the plant used for calculations of control signal. Adaptation of weights in neural networks is done in on-line mode. Article contains theoretical description of implemented control structure, simulation tests as well as experimental tests using digital signal processor of dSPACE1103. (**Internal Model Control based on neural networks applied for drive with elastic coupling**).

Słowa kluczowe: rekurencyjne sieci neuronowe, sterowanie adaptacyjne, sterowanie z modelem wewnętrznym, układ dwumasowy

Keywords: recurrent neural networks, adaptive control, internal model control, two-mass system

Wstęp

Układy napędowe o złożonej części mechanicznej, uwzględniające nieliniowości w modelu matematycznym lub elastyczny wał sprzęgający silnik z maszyną roboczą, bardzo często wymagają zastosowania zaawansowanych algorytmów sterowania [1], [2]. Dodatkowym utrudnieniem, w realizacji założeń związanych z precyzyjną kontrolą zmiennych stanu, jest również wpływ błędnej identyfikacji parametrów obiektu sterowanego [3]. W takich przypadkach klasyczne układy, wykorzystujące regulatory PI/PID, mogą okazywać się niewystarczające do spełnienia założeń projektowych napędu. W związku z powyższą przedstawionymi wymaganiami, korzystnym rozwiązaniem jest aplikacja adaptacyjnych struktur sterowania. Zakładają one dostrajanie regulatora do warunków pracy sterowanego procesu/objektu. W ten sposób uzyskiwana jest zwiększona dokładność kontroli sygnału (prędkości lub położenia), poprzez korektę nastaw regulatora, w obecności zakłóceń pojawiających się w strukturze sterowania [4].

Istotną grupę, w algorytmach adaptacyjnych, w tym również często stosowanych dla napędu elektrycznego, stanowią metody wykorzystujące logikę rozmytą oraz sieci neuronowe [3]-[5]. Zaletą regulatorów opartych o wymienione techniki jest brak konieczności posiadania równań matematycznych oraz informacji dotyczących stałych czasowych obiektu. Założeniem metod projektowania, które zakładają wykorzystanie obserwacji działania sterowanego systemu do utworzenia bazy reguł regulatora (regulatory rozmyte) lub dostrajanie znacznej liczby współczynników w celu reprezentacji odpowiedniego działania modelu (sieci neuronowe), jest wprowadzenie redukcji wpływu zmian parametrów na dokładność sterowania. Prezentowany artykuł przedstawia analizę możliwości zastosowania rekurencyjnej sieci neuronowej w układzie regulacji prędkości napędu elektrycznego. W zadaniu wykorzystane zostały rekurencyjne sieci neuronowe (**Recurrent Neural Networks**). Charakterystycznym elementem struktury zastosowanych modeli jest występowanie dodatkowych wewnętrznych sprzężeń zwrotnych [6]. Opisana modyfikacja, w porównaniu z klasycznymi sieciami perceptronowymi (**Multi-Layer Perceptrons**), ma na celu poprawienie działania w trakcie przetwarzania sygnałów dynamicznych. Wartość wyjściowa modelu neuronowego RNN, w danym kroku obliczeń, jest zależna od aktualnego stanu wektora zmiennych wejściowych, a także od wartości z poprzednich

stanów pracy układu regulacji. W wielu przypadkach aplikacji sieci MLP, podobne działania realizowane są poprzez odpowiednie modyfikacje wektora wejściowego. Jednak zasady w takim postępowaniu nie zostały precyzyjnie opisane w literaturze (np. liczba dodatkowych opóźnień wejściowych). Ponadto, liczba współczynników reprezentujących stan działania systemu w poprzednim cyklu pracy (opóźnień struktury sieci neuronowej) jest mniejsza w przypadku modeli MLP [7].

Implementacje rekurencyjnych sieci neuronowych, w zastosowaniach związanych z napędami elektrycznymi, są obecnie bardzo często opisywane. Najczęściej wykorzystywanymi topologiami są sieci Jordana oraz Elmana [8], [9]. Pierwsza z nich wykorzystuje dodatkowe sprzężenie globalne modelu, z wyjścia sieci neuronowej do wektora wejściowego. Natomiast sieć Elmana charakteryzuje się występowaniem sprzężeń rekurencyjnych w poszczególnych neuronach warstwy ukrytej. RNN spełniają funkcję regulatorów w napędach z silnikami indukcyjnymi [10] oraz prądu stałego [11]. Oddzielna część zastosowań dotyczy odtwarzania zmiennych stanu [12], [13] oraz kompensacji uchybów regulacji [14].

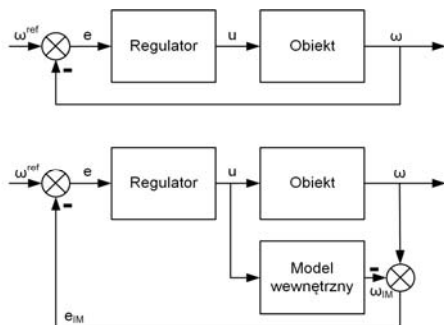
W opisywanej pracy, podstawową strukturę sterowania prędkością stanowi układ z modelem wewnętrznym – **Internal Model Control**. Charakterystycznym założeniem metody jest wprowadzenie dodatkowego modelu sterowanego procesu, którego zadaniem (rysunek 1), poprzez interakcję z regulatorem, jest poprawienie działania (w porównaniu do sterowania bezpośredniego) w obecności zakłóceń [15]. Pojawia się jednak kolejny problem projektowy dotyczący opracowania modelu wewnętrznego. Możliwe jest wyznaczenie analityczne tej części układu regulacji [16]. Jednak bardziej korzystne wydaje się wprowadzenie adaptacyjnego modelu neuronowego, dostrajanego do reprezentacji obiektu [17]. Jeśli trening sieci neuronowych realizowany jest on-line, uproszczony zostaje etap projektowania (brak konieczności zbierania danych treningowych, decydowania o złożoności modelu, współczynników uczenia, itp.) oraz możliwa jest reakcja na zmiany stałych czasowych części mechanicznej napędu. Efektywne zastosowanie sieci neuronowych połączonych w strukturze sterowania z modelem wewnętrznym, dla serwomechanizmu z silnikami PMSM, przedstawiono w publikacji [18]. Modele, trenowane za pomocą uproszczonego algorytmu adaptacyjnego (**Resilient**

BackPROPagation algorithm), dostosowują się do realizacji zadania w trakcie pracy systemu, bez dodatkowej wstępnej identyfikacji obiektu.


Prezentowany artykuł opisuje możliwość aplikacji rekurencyjnych sieci neuronowych w strukturze sterowania układem dwumasowym. W badaniach eksperymentalnych taki model odpowiada części mechanicznej napędu elektrycznego. Kolejne rozdziały przedstawiają założenia analizowanej struktury sterowania oraz sposób obliczeń sieci rekurencyjnych. W ostatnich rozdziałach publikacji zamieszczono wyniki badań symulacyjnych oraz weryfikację eksperymentalną.

Opis struktury sterowania

Podstawową cechą wyróżniającą metodę sterowania IMC jest wykorzystanie informacji o różnicy prędkości pomiędzy obiektem oraz modelem wewnętrznym. Sygnał wykorzystywany jest w trakcie obliczeń błędu na wejściu regulatora prędkości (rysunek 1). W opisywanych badaniach założono również wykorzystanie prędkości pierwszej napędu. W ten sposób kontrola układu jest utrudniona, jednak napęd nie wymaga dodatkowych układów pomiarowych lub estymatorów. Szczegóły analizowanej struktury sterowania zaprezentowano na rysunku 2. W układzie wykorzystano sieci neuronowe z połączeniami rekurencyjnymi.



Rys.1. Podstawowy schemat klasycznego sterowania ze sprzężeniem zwrotnym (a) oraz układ regulacji z modelem wewnętrznym (b)



Rys.2. Struktura sterowania

Układ dwumasowy opisany jest następującym układem równań [19]:

$$(1) \quad \begin{aligned} \frac{d\omega_1}{dt} &= \frac{1}{T_1} (m_e - m_s - m_{f1}) \\ \frac{d\omega_2}{dt} &= \frac{1}{T_2} (m_s - m_L - m_{f2}), \\ \frac{dm_s}{dt} &= \frac{1}{T_c} (\omega_1 - \omega_2) \end{aligned}$$

gdzie: ω_1, ω_2 – prędkości silnika i maszyny roboczej, m_s, m_e – moment skrotny i elektromagnetyczny, m_L – moment obciążenia, T_1, T_2, T_c – mechaniczna stała czasowa silnika,

obciążenia oraz stała czasowa elementu sprężystego, m_{f1}, m_{f2} – funkcje opisujące tarcie. W opisie układu dwumasowego uwzględniono model tarcia, opisany za pomocą równania [20]:

$$(2) \quad m_{fi} = \text{sign}(\omega_i)(c|\omega_i| + d),$$

gdzie: c odpowiada współczynnikowi tarcia wiskotycznego a d tarcia Coulombowskiego

W celu uproszczenia struktury część kształtująca moment elektromagnetyczny, w wewnętrznej pętli sterowania, została zastąpiona przez element inercyjny pierwszego rzędu:

$$(3) \quad G_{me}(s) = \frac{1}{T_{me}s + 1},$$

gdzie T_{me} oznacza stałą czasową układu regulacji prądu.

Model rekurencyjnych sieci neuronowych wykorzystanych w adaptacyjnym układzie regulacji z modelem wewnętrznym

Wykorzystywana sieć rekurencyjna składa się z dwóch liniowych neuronów w warstwie wejściowej, pięciu neuronów warstwy ukrytej oraz neuronu wyjściowego. Sygnałem wejściowym sieci jest sygnał:

$$(4) \quad in_1(t) = \omega_{ref} - (\omega_1 - \omega_{IM}) = \omega_{ref} - e_{IM},$$

gdzie: ω_{ref} – wartość zadana prędkości, ω_{IM} – wyjście modelu wewnętrznego. Jako funkcję aktywacji neuronów w sieci użyto tangens hiperboliczny. Opisywany jest on wzorem:

$$(5) \quad \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}.$$

Równania matematyczne opisujące warstwę ukrytą sieci przedstawiają się następująco

$$(6) \quad hi(t) = \sum_{i,h} (w_{ih}x_i(t)) + b_h,$$

$$(7) \quad ho(t) = f(hi(t)),$$

gdzie: i, h – numer wejścia oraz neuronu ukrytego, x – sygnał wejściowy, w, b – wagi oraz bias dla poszczególnych neuronów. Neuron wyjściowy reprezentują równania:

$$(8) \quad oi(t) = \sum_{h,o} (w_{ho}ho(t)) + b_o,$$

$$(9) \quad onn(t) = f(oi(t)),$$

gdzie: $o=1$ – indeks neuronu wyjściowego. Sygnał onn pełni również funkcję drugiego wejścia sieci. Sygnał ten jest wcześniej mnożony przez odpowiedni współczynnik wagowy zgodnie z (10).

$$(10) \quad in_2(t) = onn(t)w_{rec}(t).$$

Wszystkie wagi sieci (oznaczone w) podlegają adaptacji podczas pracy napędu zgodnie z równaniem (11):

$$(11) \quad \mathbf{w}_{ij}^{new}(k+1) = \mathbf{w}_{ij} - \eta \Delta \mathbf{w}_{ij}(k),$$

gdzie: \mathbf{w}_{ij} – wektor wag pomiędzy warstwami i oraz j , $\Delta \mathbf{w}_{ij}$ – poprawka wag, η – współczynnik skalujący, k – numer próbki. Wprowadzona poprawka dla wag w warstwie ukrytej oraz wyjściowej obliczana jest na podstawie poniższych wzorów (12-14):

$$(12) \quad \Delta w_{ij} = \frac{\partial E}{\partial w_{ij}},$$

$$(13) \quad \frac{\partial E}{\partial w_{ho}} = \frac{\partial E}{\partial onn} \frac{\partial onn}{\partial oi} \frac{\partial oi}{\partial w_{ho}},$$

$$(14) \quad \frac{\partial E}{\partial w_{ih}} = \frac{\partial E}{\partial ho} \frac{\partial ho}{\partial hi} \frac{\partial hi}{\partial w_{ih}}.$$

Wartość pochodnej funkcji celu w stosunku do wyjścia opisywana jest zależnością (15):

$$(15) \quad \frac{\partial E}{\partial onn} = e^m = \omega_{ref}^m - \omega_1,$$

gdzie: ω_{ref}^m - prędkość modelu referencyjnego. Jako transmitancje referencyjną użyto obiektu inercyjnego drugiego rzędu o transmitancji:

$$(16) \quad G^m(s) = \frac{\omega_r^2}{s^2 + 2\xi\omega_r s + \omega_r^2},$$

gdzie: ω_r - częstotliwość rezonansowa, ξ - współczynnik tłumienia, przyjęto $\omega_r = 40$ rad/sec oraz $\xi = 1$ wartości te gwarantują szybką odpowiedź przy braku przeregulowania. Aktualizacja wagi połączenia rekurencyjnego odbywa się zgodnie ze wzorami:

$$(17) \quad w_{rec}^{new}(k+1) = w_{rec}(k) - \alpha \Delta w_{rec}(k),$$

$$(18) \quad \Delta w_{rec}(k) = e^m(k) onn(k),$$

gdzie: α - współczynnik uczenia dla wagi rekurencyjnej. Należy zauważyć, że struktura obu sieci neuronowych jest tożsama z tą różnicą, że wejścia sieci pełniące rolę modelu wewnętrznego zdefiniowane są następująco:

$$(19) \quad inn_1^{IM}(t) = m_e,$$

$$(20) \quad inn_2^{IM}(t) = onn^{IM}(t) w_{rec}^{IM}(t) = w_{rec}^{IM}(t) \omega_{im}.$$


Sieci neuronowe były uczone w trybie *on-line* zgodnie z kryterium:

$$(21) \quad f = \omega_{ref} - \omega_1.$$

Wyniki badań symulacyjnych

Opisywana struktura została zaimplementowana w środowisku Matlab z wykorzystaniem pakietu Simulink. Zastosowano krok całkowania 0,1 ms. Przyjęto następujące parametry układu dwumasowego: $T_1 = T_2 = 0,203$ s, $T_c = 1,2$ ms. Zadano prędkość równą 25% prędkości znamionowej, w testach wymuszano cykliczne nawroty. W czasie $t = 8,5$ s następuje załączenie znamionowej wartości momentu obciążenia, a w $t = 9,5$ s jest ono odłączane. Dobór takich parametrów modeli neuronowych jak współczynnik adaptacji oraz wagi początkowe, może być problematyczny. Wartości wag w stanie początkowym są często dobierane za pomocą generatora liczb losowych, takie podejście ma jednak wpływ na późniejsze działanie układu regulacji. Wartość współczynnika uczenia najczęściej dobierana jest w taki sposób, aby w jak najszybszy sposób zniwelować przeregulowanie. Kolejnym kryterium jest też zbieżność odpowiedzi układu napędowego z prędkością zadaną.


Wagi oraz współczynnik uczenia obu modeli neuronowych zostały dobrane w ten sposób, aby jak zminimalizować przeregulowanie oraz oscylacje, które mogą pojawić się podczas uruchamiania struktury.



Rys.3. Przebiegi prędkości silnika ω_1 oraz obciążenia ω_2 , a także momentów: skrętnego m_s i elektromagnetycznego m_e

Badania rozpoczęte zostały od testów wykonanych dla znamionowych parametrów napędu. Przeregulowanie w układzie występuje tylko w początkowej fazie działania napędu. Dzięki adaptacji parametrów regulatora oraz modelu wewnętrznego, układ z wysoką dokładnością odtwarza prędkość zadaną. Niewielkie zakłócenia w przebiegach zmiennych stanu występują podczas załączania obciążenia.


Wpływ zmian parametrów układu dwumasowego na jakość sterowania został zaprezentowany na kolejnych przebiegach. Po zwiększeniu stałej czasowej związanej z obciążeniem (rysunek 4), zauważalne są zwiększone oscylacje w przebiegu prędkości podczas przełączania obciążenia. Pojawia się niewielkie przeregulowanie, które jest niwelowane w czasie dalszego działania układu. Mimo zmian parametrycznych układ nadal reaguje poprawnie na zadaną prędkość oraz moment obciążenia. Po zmniejszeniu stałej czasowej T_2 (rysunek 5) brak jest oscylacji podczas działania napędu. Prędkość kształtowana jest w sposób podobny jak w przypadku warunków znamionowych. Napęd reaguje szybciej, w stosunku do poprzednich przypadków, podczas przełączania obciążenia.




Rys.4. Przebiegi zmiennych stanu dla zwiększonej stałej czasowej maszyny roboczej $T_2 = 2T_{2n}$

Wyniki badań zrealizowanych po zwiększeniu stałej czasowej elementu sprężystego T_c przedstawione zostały na rysunku 6. Obserwowana jest większa rozbieżność w przebiegach zmiennych stanu prędkości w trakcie przełączania obciążenia. Pojawia się również niewielkie przeregulowanie, widoczne podczas dwóch pierwszych nawrotów. Obniżenie wartości tej stałej czasowej również


nie stanowi istotnego zakłócenia dla układu (rysunek 7). Zauważalna jest zmniejszona wartość przeregulowania podczas pierwszego nawrotu. Układ regulacji skutecznie tłumi oscylacje w trakcie oddziaływania obciążenia.



Rys.5. Przebiegi zmiennych stanu dla zmniejszonej stałej czasowej maszyny roboczej $T_2 = 0,5T_{2n}$



Rys.6. Przebiegi prędkości silnika ω_1 oraz obciążenia ω_2 , a także momentów: skrotnego m_s i elektromagnetycznego m_e zarejestrowane dla zwiększonej stałej czasowej elementu sprężystego




Rys.7. Przebiegi zmiennych stanu uzyskane dla $T_c = 0,5T_{cn}$


Następne badania prezentują porównanie adaptacyjnych regulatorów prędkości wykorzystujących różne struktury neuronowe. Testowano aplikację modelu rekurencyjnego oraz jednokierunkowej sieci. Wyniki badań przedstawiono na rysunku 8. Należy zaznaczyć, że w obu przypadkach wprowadzono identyczne wartości współczynnika algorytmu adaptacyjnego oraz wag

początkowych. Różnica w przebiegach prędkości nie jest jednoznacznie widoczna na głównym przebiegu. Na podstawie przybliżenia można stwierdzić, że wprowadzenie nawet jednego dodatkowego sprzężenia do sieci neuronowej poprawia działanie regulatora w stanach dynamicznych pracy napędu. Reakcja układu regulacji jest szybsza, w przypadku dokonywania nawrotów oraz przy zmianach obciążenia. Nakład obliczeniowy w porównaniu do klasycznej sieci neuronowej jest niewiele większy.

Kolejne testy przedstawiają przedstawione na rysunku 9 prezentują wpływ współczynnika uczenia regulatora neuronowego na działanie układu napędowego. Różnica w przebiegach prędkości widoczna jest głównie przy dokonywaniu dwóch pierwszych nawrotów. Przebiegi oznaczone kolorem czerwony prezentują wolniejszy proces adaptacji oraz zwiększone przeregulowanie w stosunku do pozostałych przebiegów. Kolor niebieski natomiast charakteryzuje się zwiększoną częstotliwością drgań. Bez względu na wartość tego parametru układ napędowy jest stabilny, a odpowiedź na prędkość zadaną po dokonaniu kilku nawrotów jest tożsama.




Rys.8. Wpływ architektury sieci neuronowej włączonej do pętli sterowania prędkością



Rys.9. Wpływ współczynnika algorytmu adaptacyjnego na działanie układu regulacji


Ostatnia część badań symulacyjnych polegała na sprawdzeniu wpływu początkowych wag modelu neuronowego na reakcję badanego obiektu. Kolorem czerwonym oznaczono wartości pięciokrotnie mniejsze od wartości użytych w poprzednich badaniach. Kolor niebieski reprezentuje wartości dwukrotnie większe. Przy zbyt małych wartościach początkowych zaobserwowano zwiększoną wartość przeregulowania. Zwiększone wartości tych parametrów skutkuje krótkotrwałym uderzeniem prędkości w kierunku przeciwnym do zadanego oraz występowaniem oscylacji po zadaniu momentu obciążenia w układzie.



Rys.10. Przebiegi prędkości maszyny roboczej uzyskane dla różnych wartości początkowych współczynników wagowych RNN

Badania laboratoryjne


Badania eksperymentalne zostały wykonane na stanowisku laboratoryjnym, składającym się z dwóch silników prądu stałego (o mocy 500W każdy). Budowę rzeczywistego zestawu badawczego przedstawiono na rysunku 11. Maszyny zostały sprzęgnięte za pomocą elastycznego wału, o długości 0,6 m i średnicy 5 mm. Stała czasowa maszyny roboczej może być modyfikowana poprzez zamontowanie dodatkowej tarczy na wale silnika. Prędkość obu silników mierzono za pomocą enkoderów inkrementalnych. Poszczególne elementy algorytmu sterowania: regulator prędkości (modele neuronowe), pętla kontroli momentu elektromagnetycznego oraz obsługa układów zasilających energoelektronikę, zostały zaimplementowane w procesorze karty DS1103.




Rys.11. Stanowisko laboratoryjne

Wyniki serii badań eksperymentalnych zostały przedstawione poniżej. Wykonano badania dla prędkości analogicznej do badań symulacyjnych, dla warunków znamionowych oraz po założeniu dodatkowej tarczy na wał, co skutkowało zwiększeniem stałej czasowej. Rysunek 12 prezentuje uzyskane przebiegi zmiennych stanu uzyskane dla warunków znamionowych. Dynamika uzyskiwanych przebiegów jest zbliżona do tej uzyskiwanej w badaniach symulacyjnych. Brak jest przeregulowań oraz uchybów prędkości. Po załączeniu obciążenia silnik reaguje w sposób poprawny

Ostatnie badania zostały przeprowadzone po zwiększeniu stałej czasowej silnika obciążającego (dodatkowa tarcza po stronie obciążenia). Na przebiegach (rysunek 13) widoczny jest proces adaptacji podczas pracy układu. Na wykresach prędkości zauważalne jest przeregulowanie, które ulega zmniejszeniu wraz z dokonywaniem kolejnych nawrotów w trakcie działania napędu.



Rys.12. Przebiegi zmiennych stanu w układzie napędowym – badania eksperymentalne, a) bez załączania obciążenia, b) z obciążeniem



Rys.13. Przebiegi prędkości napędu dla zwiększonej stałej czasowej obciążenia

Podsumowanie

Niniejszy artykuł przedstawia wstępne wyniki badań dotyczących aplikacji rekurencyjnych sieci neuronowych w sterowaniu układem napędowym z silnikami prądu stałego, zawierającym elastyczne sprzęgło. Testowane modele adaptacyjne zaimplementowano w strukturze sterowania wykorzystującej model wewnętrzny. Otrzymane wyniki, symulacyjne oraz eksperymentalne, umożliwiają przedstawienie poniższych konkluzji.

- Zastosowanie sieci neuronowych, zawierających wewnętrzne sprzężenia zwrotne, umożliwia precyzyjne oraz dynamiczne sterowanie napędem elektrycznym.
- Uzyskane rezultaty badań przedstawiają szybszą reakcję regulatora na zmiany zmiennych stanu, w porównaniu do klasycznych sieci perceptronowych zastosowanych w tym samym zadaniu.
- Testowana struktura sterowania wprowadza korekty nastaw umożliwiające redukcję uchybu prędkości, pojawiającą się w wyniku zmian parametrów układu dwumasowego.
- Wprowadzenie neuronowego modelu wewnętrznego, a w szczególności adaptowanego on-line, do układu regulacji prędkości wprowadza istotne uproszczenia projektowe, które związane są z brakiem konieczności wyznaczania parametrów tego elementu struktury. Przedstawione

założenie może prowadzić do większej odporności układu na zakłócenia pojawiające się w obiekcie.

Autorzy: mgr inż. Mateusz Żychlewicz, dr Piotr Derugo, Politechnika Wroclawska, Katedra Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, E-mail: mateusz.zychlewicz@pwr.edu.pl, piotr.derugo@pwr.edu.pl

LITERATURA

- [1] Derugo P., Szabat K., Damping of torsional vibrations of two-mass system using adaptive low computational cost fuzzy PID controller, *IEEE International Conference on Power Electronics and Drive Systems*, (2015), 1162-1165
- [2] Serkies P., Szabat K., Predictive position control of the induction two-mass system drive, *IEEE International Symposium on Industrial Electronics (ISIE)*, (2014), 871-876
- [3] Kaminski M., Orłowska-Kowalska T., FPGA Implementation of ADALINE-Based Speed Controller in a Two-Mass System, *IEEE Transactions on Industrial Informatics*, 9 (2013), n. 3, 1301-1311
- [4] Yousefi F., Alipour K., Tarvirdizadeh B., Hadi A., Knee Rehabilitation Robot Control by Sliding-Backstepping and Admittance Control, *Artificial Intelligence and Robotics*, (2017), 51-57
- [5] Nowopolski K., Wicher B., Łuczak D., Siwek P., Recursive neural network as speed controller for two-sided electrical drive with complex mechanical structure, *International Conference on Methods and Models in Automation and Robotics (MMAR)*, (2017), 576-581
- [6] Benmabrouk Z., Abid A., Ben Hamed M., Sbita L., Speed control of DC machine using adaptive neural IMC controller based on recurrent neural network, *International Conference on Systems and Control (ICSC)*, (2016), 198-203
- [7] Guo B., Hu L., Bai Y., PMSM servo system based on dynamic Recurrent Neural Networks PID controller, *Proceedings of International Power Electronics and Motion Control Conference*, 4, (2012), 2417-2421
- [8] Kamiński M., Recurrent neural controller applied for two-mass system, *International Conference on Methods and Models in Automation and Robotics (MMAR)*, (2016), 128-133
- [9] El-Sousy F. F. M., Intelligent Optimal Recurrent Wavelet Elman Neural Network Control System for Permanent-Magnet Synchronous Motor Servo Drive, *IEEE Transaction on Industrial Informatics*, 9, (2013), n. 4, 1986-2003
- [10] Wai R.-J., Lin F.-J., Adaptive recurrent-neural-network control for linear induction motor, *IEEE Transactions on Aerospace and Electronics Systems*, 37, (2001), n. 4, 1176-1192
- [11] Castaneda C., Lopez-Mancilla D., Garcia J. H., Zarate R. C., Position Control of DC Motor based on Recurrent High Order Neural Networks, *IEEE International Symposium on Intelligent Control*, (2010), 1515-1520
- [12] Tsai C.-H., Neural Network Application for Flux and Speed Estimation in the Sensorless Decoupling Induction Drive, *IEEE International Conference on Systems, Man and Cybernetics (SMC)*, (2006), 5297-5303
- [13] El-Sousy F. F. M., Abuhasel K. A., Adaptive nonlinear disturbance observer using double loop self-organizing recurrent wavelet-neural-network for two-axis motion control system, *IEEE Industry Applications Society Annual Meeting*, (2016), 1-14
- [14] Lin F.-J., Lin C.-H., Hong C.-M. Robust control of linear synchronous motor servodrive using disturbance observer and recurrent neural network compensator, *IEE Proceedings – Electric Power Applications*, 147, (2000), n. 4, 263-272
- [15] Francis B., Wonham W., The internal model principle of control theory, *Automatica*, 12, (1976), n. 5, 457-465
- [16] D. Chao, Zhonggang Y., Yanqing Z., Xiangdong S., Jing L., Yanru Z., Decoupled Current Control of Induction Motors Drives with Internal Model Based on Active Disturbance Rejection Control Strategy, *International Conference on Electrical Machines and Systems (ICEMS)*, 2016, 1-6
- [17] Li H.-X., Deng H., An Approximate Internal Model-Based Neural Control for Unknown Nonlinear Discrete Processes, *IEEE Transactions on Neural Networks*, 17, (2006), n. 3., 659-670
- [18] Pajchrowski T., Application of an Internal Model Speed Control for PMSM with variable mechanical parameters, *International Conference on Cybernetics (CYBCONF)*, (2015), 416-421
- [19] Wróbel K., Adaptacyjne sterowanie rozmyte ze zbiorami typu II złożonego układu napędowego pracującego w zakresie prędkości niskiej, *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej. Studia i Materiały*, 71 (2015), nr 35, 109-117
- [20] Bona B., Indri M., Friction Compensation in Robotics: an Overview, *IEEE Conference on Decision and Control*, (2005), 4360-4367