

## Neuronowy generator wirtualnej zmiennej stanu w regulatorze prędkości układu dwumasowego

**Streszczenie.** W publikacji przedstawiona została modyfikacja klasycznego regulatora stanu, która zakłada wprowadzenie radialnej sieci neuronowej (Radial Basis Function Neural Network). Celem jest wygenerowanie sygnału, który zostanie wprowadzony do wektora zmiennych stanu sprzężeń zwrotnych. Obiektem regulacji jest napęd elektryczny z połączeniem sprężystym. W artykule uwzględniono opis teoretyczny proponowanego rozwiązania, a także zaprezentowano wyniki badań symulacyjnych struktury sterowania. Badania przeprowadzone dla rzeczywistego układu napędowego stanowią dodatkową weryfikację analizowanego regulatora stanu.

**Abstract.** In this paper, a state feedback controller enhanced by a Radial Basis Function Neural Network is presented. The main goal of the network is calculation of a virtual signal used in state vector and applied as feedback. The plant considered in the article is an electrical drive with a flexible joint. The mathematical description of the proposed control scheme and the numerical tests can be found in the manuscript. Experimental analysis is performed as an additional verification of the proposed state controller. (Neural generator of a virtual state variable used in speed control of a two-mass system).

**Słowa kluczowe:** regulator stanu, radialna sieć neuronowa, sterowanie adaptacyjne, układ dwumasowy.

**Keywords:** state feedback controller, radial basis function neural network, adaptive control, two-mass system.

### Wstęp

W wielu aplikacjach napędów elektrycznych, takich jak roboty przemysłowe [1], [2], napędy maszyn papierniczych [3], walcarki [4], czy też generatory wiatrowe [5], spełnienie wymagań dotyczących precyzji oraz dynamiki sterowania jest utrudnione z powodu specyficznej konstrukcji części mechanicznej. We wszystkich wymienionych systemach silnik połączony jest z maszyną roboczą poprzez element poddający się siłom skręcającym. W wyniku występowania naprężeń na wale przebiegi prędkości obrotowej silnika oraz maszyny roboczej nie posiadają identycznych trajektorii. Pojawiają się również oscylacje zmiennych stanu [6], które mogą być przyczyną wielu niepożądanych efektów, wśród których wymienić można obniżenie jakości procesu przemysłowego [7], pogorszenie stanu części mechanicznej napędu (mogące prowadzić nawet do jej trwałego uszkodzenia) [8] lub utratę stabilności [9].

Skutecznym rozwiązaniem problemu jest zastosowanie kaskadowej struktury z regulatorem stanu odpowiedzialnym za regulację prędkości [10], [11]. Do podstawowych zalet tego regulatora zaliczyć można wysoką dokładność odtwarzania zadanej trajektorii oraz niską złożoność obliczeniową (a co za tym idzie prostotę implementacji praktycznej i możliwe obniżenie kosztów układu). Warunkiem uzyskania wyżej wymienionych cech jest dokładna identyfikacja parametrów układu i zapewnienie stałych warunków pracy [12].

W celu wyeliminowania wpływu zmian parametrów obiektu podstawowe struktury sterowania rozszerzane są o właściwości adaptacyjne [13]. Dostrajanie parametrów uzyskiwane jest poprzez wykorzystanie klasycznych struktur sterowania opartych o model odniesienia (*Model Reference Adaptive Control*) [14] lub zastosowanie algorytmów sztucznej inteligencji opartych np. o sieci neuronowe [15] bądź logikę rozmytą [16].

W odróżnieniu od strategii sterowania z modelem odniesienia, w podejściu neuronowym, z adaptacją wag w trybie *online*, nie występuje konieczność wprowadzania modelu zachowania obiektu. Istnieje jednak szereg parametrów projektowych, które należy starannie dobrać [17]. Jednym z nich jest wartość współczynnika uczenia

bezpośrednio wpływająca na dynamikę adaptacji wag. Istotny jest również dobór struktury sieci neuronowej (rodzaj funkcji aktywacji, liczba neuronów w poszczególnych warstwach oraz ewentualne dołączenie połączeń rekurencyjnych). Może również zaistnieć potrzeba odpowiedniego doboru wartości początkowych wag sieci – niekorzystny punkt startowy może doprowadzić do intensywnych oscylacji w chwili rozpoczęcia działania układu napędowego [18].

Charakterystyczną cechą regulatora stanu, istotną w rzeczywistych aplikacjach przemysłowych, jest konieczność pomiaru lub odtwarzania sygnałów włączanych do sprzężeń zwrotnych. Wspomniane zadanie może powodować wzrost kosztów konstrukcji lub zwiększenie podatności na uszkodzenia. Zastosowanie obserwatorów wprowadza dodatkowe utrudnienia aplikacyjne oraz dodatkowe współczynniki zależne od parametrów obiektu [19]. W związku z powyższym, w niniejszej pracy, w regulatorze stanu zastosowano radialną sieć neuronową w celu zastąpienia toru sprzężenia zwrotnego od momentu skrętnego. Oprócz wprowadzenia właściwości adaptacyjnych struktury sterowania, uzyskano również zmniejszenie liczby koniecznych do estymacji zmiennych stanu (sygnały wejściowe sieci neuronowej stanowią kolejne próbki prędkości maszyny roboczej).

### Opis matematyczny struktury sterowania

Schemat proponowanej struktury sterowania został przedstawiony na rysunku 1. Pierwszy etap procesu projektowania dotyczył doboru nastaw klasycznego regulatora stanu (ze sprzężeniem od momentu skrętnego zaznaczonym za pomocą linii przerywanej) zgodnie z metodą lokowania biegunów równania charakterystycznego. Analizowanym obiektem sterowania jest zestaw dwóch maszyn elektrycznych prądu stałego sprzęgniętych za pomocą elastycznego elementu (długiego, cienkiego, stalowego wału). W literaturze tego typu konstrukcje określane są układami dwumasowymi. Właściwości dynamiczne systemu opisuje (w jednostkach względnych) następujący układ równań różniczkowych [20]-[22]:



$$(14) \quad \Delta W(i) = -\eta (d(i) - y_{rbf}(i)) \mathbf{H}(i).$$

W przedstawianej strukturze sterowania celem treningu sieci neuronowej jest uzyskanie zadanego przebiegu prędkości. Stąd równanie (14) przyjmuje postać:

$$(15) \quad \Delta W(i) = -\eta (\omega_{refm}(i) - \omega_2(i)) \mathbf{H}(i),$$

gdzie:  $\omega_{refm}$  – wyjście filtra wartości zadanej.

Radialna sieć neuronowa została zastosowana w celu zastąpienia toru sprzężenia zwrotnego od momentu skrętnego (Rys.1).

### Badania symulacyjne

W celu przeprowadzenia testów numerycznych zaprezentowana neuronowa struktura sterowania napędem elektrycznym z połączeniem sprzężystym została zamodelowana w środowisku Matlab/Simulink. W symulacjach przyjęto następujące parametry układu regulacji: stała czasowa silnika i maszyny roboczej  $T_1 = T_2 = 0,203$  s, stała czasowa wału łączącego maszyny  $T_c = 0,0012$  s, wartość współczynnika uczenia (pomijając testy przedstawiające wpływ stałej uczenia)  $\eta = 0,005$ . Wartości początkowe wag dobrane były losowo (z zakresu: (0, 0,01)). W warstwie ukrytej umieszczono neurony radialne o współczynnikach skalujących  $\sigma = 0,5$  (wartość nie podlegała optymalizacji, w dalszych pracach planowane jest zastosowanie algorytmu metaheurystycznego). Wejście sieci stanowią dwa sygnały – obecna oraz poprzednia próbka prędkości maszyny roboczej.


Topologia sieci neuronowej dobrana została na drodze eksperymentalnej. Zweryfikowano działanie układu sterowania przy zmienianej liczbie neuronów radialnych ( $n = 3, n = 5$  oraz  $n = 9$ ). Przebiegi prędkości kątowej maszyny roboczej dla każdego z przypadków przedstawiono na rysunku 3. Dla opisanych wyżej parametrów sieci neuronowej największą dokładność odwzorowania trajektorii zadanej uzyskano dla struktury o pięciu neuronach ukrytych. Wybraną topologię zastosowano do przeprowadzenia dalszych testów. Należy jednak zaznaczyć, że niniejsze badania nie stanowią idealnego przykładu wyznaczania najlepszej budowy regulatora. W kolejnych przypadkach należałoby odpowiednio zoptymalizować parametry struktury sterowania (np. wartość współczynnika uczenia  $\eta$ ) dla każdej analizowanej topologii sieci.

Następnie sprawdzone zostało działanie układu dla znamionowych parametrów obiektu. Rysunek 4 przedstawia przebiegi prędkości: silnika i maszyny roboczej, a także przebiegi momentów: elektromagnetycznego i skrętnego. Dodatkowo przedstawiono również zmiany współczynników wagowych radialnej sieci neuronowej.


Zgodnie ze wstępnymi założeniami, obserwowalna jest adaptacja parametrów regulatora w początkowej fazie pracy układu napędowego (gasnące oscylacje prędkości przy rozpędzaniu silnika). Układ działa stabilnie, prędkości silników dokładnie odtwarzają sygnał zadany. Widoczna jest także szybka reakcja na załączane obciążenie ( $t = 9,5$  s). Aktualizacja współczynników wewnętrznych sieci neuronowej (15) wprowadza, w kolejnych nawrotach, kształtowanie wirtualnego sygnału regulatora stanu.

W następnych badaniach przeprowadzono weryfikację wpływu zmiany parametrów obiektu – czterokrotne zwiększenie stałej czasowej  $T_2$  – na pracę proponowanej struktury sterowania. Wyniki porównano również z klasycznym regulatorem stanu. Uzyskane przebiegi przedstawione zostały na rysunku 5. Zauważalna jest zdecydowana poprawa przebiegu prędkości maszyny roboczej w przypadku regulatora stanu z siecią neuronową. W trakcie obliczeń dostrajany jest model RBFNN,

uzyskiwany jest odpowiedni sygnał wyjściowy  $y_{rbf}$ . W ten sposób obserwowana jest kompensacja zakłóceń parametrycznych w sterowanym obiekcie. W stanach przejściowych (po wykonaniu nawrotu) prędkość maszyny roboczej charakteryzuje się brakiem przeregulowania. Należy zaznaczyć, że wszystkie wzmacnienia zostały wyznaczone zgodnie ze wzorami (5)-(8) dla znamionowych stałych czasowych. W związku z tym, podstawowa wersja regulatora (RS) wprowadza istotne przeregulowania kontrolowanego sygnału.




Rys.3. Przebiegi prędkości maszyny roboczej dla różnej liczby neuronów w warstwie ukrytej




Rys.4. Przebiegi prędkości silnika ( $\omega_1$ ), maszyny roboczej ( $\omega_2$ ), momentu elektromagnetycznego ( $m_e$ ), momentu skrętnego ( $m_s$ ) oraz współczynników wagowych w strukturze sterowania z neuronowym regulatorem stanu (NRS) – testy wykonane dla znamionowych parametrów układu dwumasowego

Dla rozważanego przypadku wykonane zostało również przedstawienie prędkości maszyny roboczej w funkcji prędkości silnika. W związku z czterokrotnie zwiększoną stałą maszyny roboczej oraz sprzężystym sprzęgłem układu, spodziewane były istotne różnice pomiędzy prędkościami. Rysunek 6 przedstawia porównanie zależności  $\omega_2 = f(\omega_1)$  do przypadku idealnego (połączenia sztywnego, w którym prędkość maszyny roboczej jest zawsze równa prędkości silnika). Po zastosowaniu regulatora stanu z załączoną siecią neuronową (NRS) zaobserwować można jedynie niewielkie odchylenia od zaznaczonej czarnym kolorem idealnej zgodności prędkości napędu. Brak bezpośredniego wprowadzenia informacji o aktualnej wartości momentu skrętnego, w strukturze z siecią neuronową, nie powoduje utraty jakości sterowania.




Rys.5. Porównanie przebiegów prędkości maszyny roboczej ( $\omega_2$ ) w strukturze sterowania z regulatorem stanu o stałych parametrach (RS) oraz po wprowadzeniu modelu neuronowego (NRS) – testy wykonane dla czterokrotnie zwiększonej stałej czasowej  $T_2$




Rys.6. Zgodność wyjściowych zmiennych układu napędowego w strukturze sterowania z regulatorem stanu o stałych parametrach (RS), po wprowadzeniu modelu neuronowego (NRS), w przypadku połączenia sztywnego (Ideal) – testy wykonane dla czterokrotnie zwiększonej stałej czasowej  $T_2$

Następne testy dotyczyły zagadnień charakterystycznych dla aplikacji napędowych z przestrajalnymi sieciami neuronowymi. Sprawdzone zostało oddziaływanie wartości parametrów badanego regulatora neuronowego (współczynnika uczenia oraz różnych wartości wag początkowych sieci neuronowej) na działanie struktury sterowania. Wyniki badań przedstawione są kolejno na rysunkach 7 oraz 8. Zgodnie z równaniem (12), wartość parametru  $\eta$  wpływa bezpośrednio na wprowadzane do sieci neuronowej poprawki algorytmu adaptacyjnego. Szybkość dostrajania modelu jest zatem zależna od współczynnika uczenia. W przypadku zastosowania niewielkiej wartości parametru  $\eta$ , wstępna faza, w której tłumione są przeregulowania, trwa znacznie dłużej. Po wprowadzeniu większej stałej uczenia, obserwowana jest poprawa działania układu regulacji. Jednak przy pewnej wartości  $\eta$ , kroki algorytmu optymalizującego wagi są zwiększone do poziomu, który powoduje krótkotrwałe oscylacje prędkości.


Wylosowane wartości wag początkowych neuronowych regulatorów adaptacyjnych, stosowanych w napędach elektrycznych, mogą powodować szarpnięcia oraz dynamiczne fluktuacje zmiennych stanu. Poza tym, zachowanie powtarzalności wyników jest utrudnione. W analizowanym regulatorze adaptacyjnym, wpływ losowania współczynników sieci jest zredukowany poprzez odpowiednie skalowanie wartości, a także współpracę z regulatorem stanu (rys. 8).



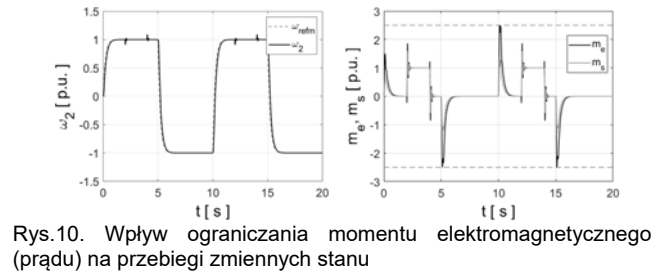
Rys.7. Wpływ wartości współczynnika uczenia sieci neuronowej na przebiegi prędkości maszyny roboczej




Rys.8. Wpływ losowania wartości początkowych wag sieci RBFNN na przebiegi prędkości maszyny roboczej napędu elektrycznego



Rys.9. Porównanie wybranych przebiegów układu regulacji z adaptacyjnym regulatorem stanu dla różnych wartości stałych czasowych zadajnika prędkości - prędkość maszyny roboczej (a) oraz sygnał generowany przez model RBFNN (b)



Rys.10. Wpływ ograniczenia momentu elektromagnetycznego (prądu) na przebiegi zmiennych stanu



Rys.11. Trajektorja prędkości maszyny roboczej dla czasu symulacji  $t_{sim} = 200$  s

Kolejnym analizowanym, w zakresie badań symulacyjnych, parametrem jest stała czasowa ( $T_{fin}$ ) zadajnika prędkości referencyjnej (człon inercyjny pierwszego rzędu). Porównanie działania testowanego układu regulacji, dla dwóch wartości tego współczynnika, przedstawione zostało na rysunku 9. Zgodnie z oczekiwaniami, stała  $T_{fin}$  wpływa na szybkość kształtowania prędkości maszyny roboczej (Rys. 9a). Struktura z dodatkowym sygnałem generowanym przez sieć neuronową poprawnie reaguje nawet na bardzo dynamiczne zmiany prędkości zadanej. Specyficzna jest zmiana charakteru przebiegu wyjściowego sieci neuronowej (Rys. 9b). Przy wymuszaniu odpowiednio wysokiej dynamiki, dostrajanie współczynników wagowych sieci neuronowej powoduje uzyskiwanie sygnału wyjściowego o kształcie zbliżonym do momentu skrajnego.

Sprawdzono również wpływ wprowadzonego ograniczenia prądu na przebiegi prędkości maszyny roboczej. Rezultaty zaprezentowane zostały na rysunku 10. Zadana została prędkość równa wartości znamionowej (w celu osiągnięcia poziomu granicznego  $lim = 2,5$ ). Zgodnie z przedstawionymi wynikami, widoczne jest nieznaczne osłabienie dynamiki. Jednak nie występują przeregulowania lub oscylacje.

W ostatnim punkcie badań, przeprowadzono praktyczną weryfikację stabilności układu. Wykonano badania potwierdzające poprawną pracę napędu dla czasu

symulacji  $t_{sim} = 200$  s. Wyniki przedstawione zostały na rysunku 11. Oprócz stabilnej pracy, widoczne są również właściwości adaptacyjne – zakłócenia, które wynikają z odłączania momentu obciążenia  $m_L$ , są redukowane w kolejnych nawrotach napędu.

### Wyniki eksperymentalne

Stanowisko laboratoryjne złożone jest z dwóch silników obcowzbudnych prądu stałego, każdy o mocy znamionowej  $P_n = 0,5$  kW. Maszyny sprzęgnięte są za pomocą stalowego pręta o średnicy  $\Phi = 6$  mm i długości  $l = 595$  mm. Silnik zasilany jest przez przekształtnik mostkowy typu H. Implementacja proponowanego neuronowego regulatora stanu zrealizowana została za pomocą karty szybkiego prototypowania dSPACE1103. Programowanie karty dSPACE wykonano poprzez stanowisko komputerowe z zainstalowanym środowiskiem Matlab/Simulink. Pomiar prądu twornika zrealizowano wykorzystując czujniki LEM. Prędkość kątowna obu maszyn mierzona jest za pomocą enkoderów inkrementalnych o rozdzielczości 36000 impulsów/obrót. Modyfikowanie układu polegające na dodaniu tarczy obciążającej po stronie maszyny roboczej lub użycie wału o innej średnicy umożliwi badanie wpływu zmian parametrów obiektu na precyzję sterowania. Rysunek 12 przedstawia zdjęcia stanowiska badawczego.




Rys. 12. Stanowisko laboratoryjne


W celu sprawdzenia poprawności działania zaproponowanej struktury sterowania przeprowadzono test, który polegał na wykonywaniu cyklicznych nawrotów w zakresie  $\pm 20\%$  prędkości znamionowej silnika. Uzyskane przebiegi prędkości maszyny roboczej, momentu elektromagnetycznego oraz skrotnego przedstawiono na rysunku 13. Włączenie momentu obciążenia nie wprowadza dodatkowego przeregulowania, układ jest stabilny, szybko powraca do wartości zadanej. Odpowiedź układu na przełączanie momentu obciążenia jest dynamiczna, odpowiada uzyskanym wynikom testów symulacyjnych.

W kolejnym etapie zweryfikowano wpływ zmiany stałej czasowej  $T_2$ . Po stronie maszyny roboczej zamontowano płytę obciążającą, której masa dobrana jest tak, aby zastępcza mechaniczna stała czasowa maszyny roboczej wynosiła  $T_2 = 4T_{2n}$  (zgodnie z wykonanymi badaniami symulacyjnymi). Przebiegi widoczne są na rysunku 14.

Zastosowanie neuronowego symulatora wirtualnej zmiennej stanu przyczynia się do stopniowego wyeliminowania przeregulowania spowodowanego występowaniem zakłócenia parametrycznego w obiekcie regulacji (zmiany momentu bezwładności maszyny roboczej). Bardzo dobrze widoczny jest wpływ adaptacji parametrów sieci neuronowej na przebieg prędkości maszyny roboczej – w końcowym etapie przebiegów oscylacje prędkości w stanie ustalonym zostały praktycznie całkowicie stłumione.



Rys. 13. Przebieg prędkości maszyny roboczej ( $\omega_2$ ), momentu elektromagnetycznego ( $m_e$ ) oraz momentu skrotnego ( $m_s$ ) w układzie sterowania z adaptacyjnym regulatorem stanu – przełączanie obciążenia



Rys. 14. Porównanie przebiegów prędkości maszyny roboczej ( $\omega_2$ ) w strukturze sterowania z regulatorem stanu o stałych parametrach (RS) oraz po wprowadzeniu modelu neuronowego (NRS) – testy wykonane dla zwiększonej stałej czasowej  $T_2$

### Podsumowanie

Celem niniejszej pracy było przedstawienie procesu implementacji zmodyfikowanej wersji regulatora stanu dla układu dwumasowego. W zaproponowanym rozwiązaniu, w strukturze sterowania, sprzężenie zwrotne od momentu skrotnego zastąpione zostało radialną siecią neuronową, która pełni funkcję symulatora (nie jest estymatorem  $m_s$ ) wirtualnej zmiennej stanu. Poza koncepcją rozbudowanego regulatora prędkości napędu, przedstawione zostały wyniki badań symulacyjnych oraz eksperymentalnych, które potwierdzają wstępne, przedstawione poniżej, założenia.

➤ Aplikacja adaptacyjnego modelu sieci radialnej, której współczynniki są przestrajane w trakcie działania napędu, umożliwia wyeliminowanie konieczności posiadania informacji o momencie skrotnym. W związku z tym, potencjalnie zwiększono niezawodność systemu oraz zredukowano koszty implementacji struktury sterowania dla obiektu rzeczywistego.

➤ Rozszerzenie regulatora stanu, zastosowanego dla napędu elektrycznego z połączeniem sprężystym, poprzez dodatkowy element neuronowy stanowi koncepcję adaptacyjnej wersji układu regulacji. Zaproponowane rozwiązanie umożliwia korektę generowanego sygnału, poprzez przestrajanie współczynników wagowych sieci, a w efekcie końcowym – poprawę precyzji sterowania w przypadku zmian parametrów obiektu.

**Autorzy:** mgr inż. Radosław Stanisławski, Politechnika Wroclawska, Wydział Elektryczny, Katedra Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, email: radoslaw.stanislawski@pwr.edu.pl; mgr inż. Mateusz Malarczyk, Politechnika Wroclawska, Wydział Elektryczny, Katedra Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, e-mail: mateusz.malarczyk@pwr.edu.pl; dr inż. Jarosław Szrek, Politechnika Wroclawska, Wydział Mechaniczny, Katedra Podstaw Konstrukcji Maszyn i Układów Mechatronicznych, ul. Łukasiewicza 7/9, 50-371 Wrocław, e-mail: jaroslaw.szrek@pwr.edu.pl; mgr inż. Mateusz Żychlewicz, Politechnika Wroclawska, Wydział

*Elektryczny, Katedra Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, e-mail: mateusz.zychlewicz@pwr.edu.pl; dr hab. inż. Marcin Kamiński, Politechnika Wrocławska, Wydział Elektryczny, Katedra Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, email: marcin.kaminski@pwr.edu.pl*

#### LITERATURA

- [1] Park H.Y., Lee S.H. Eigenvector assignment based vibration suppression control for a two link flexible joint robot arm. *International Conference on Control, Automation and Systems (2008)*, 2513-2516
- [2] Sun W., Diao S., Su S.F., Wu Y. Adaptive fuzzy tracking for flexible-joint robots with random noises via command filter control. *Information Sciences (2021)*, 575, 116-132
- [3] Valenzuela J.A., Bentley J.M., Lorenz R.D. Evaluation of torsional oscillations in paper machine sections. *IEEE Transactions on Industry Applications*, 41(6) (2005), 1458-1466
- [4] Park T.S., Shin E.C., Oh W.H., Yoo J.Y. Robust speed control for torsional vibration suppression of rolling mill drive system. *Proceedings of the 29<sup>th</sup> Annual Conference of the IEEE Industrial Electronics Society IECON '03 (2003)*, Roanoke, USA, 66-71
- [5] Rajendran S., Diaz M., Chavez H., Cruchaga M., Castillo E. Terminal Synergetic Control for Variable Speed Wind Turbine Using a Two Mass Model. *IEEE CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON) (2021)*, 1-6
- [6] Jung H., Jeon K., Oh S. Iterative Feedback Tuning of Cascade Control for Position and Velocity of Two-Mass System. *IFAC PapersOnLine (2020)*, 53(2), 8357-8362
- [7] Saito E., Katsura S. Vibration Control of a Two-Mass resonant system using wave compensator. *SICE Annual Conference (2011)*, 2672-2677
- [8] Palleschi A., Mengacci, R., Angelini F., Caporale D., Pallottino L., De Luca A., Garabini M. Time-Optimal Trajectory Planning for Flexible Joint Robots. *IEEE Robotics and Automation Letters (2020)*, 5, 938-945
- [9] Singh V.P., Kishor N., Samuel P., Singh N. Small-signal stability analysis for two-mass and three-mass shaft model of wind turbine integrated to thermal power system. *Computers & Electrical Engineering (2019)*, 78, 271-287
- [10] Serkies P., Szabat K. Effective damping of the torsional vibrations of the drive system with an elastic joint based on the forced dynamic control algorithms. *Journal of Vibration and Control (2019)*, 25(16), 2225-2236
- [11] Beck H.P., Turschner D. Commissioning of a State-Controlled High-Powered Electrical Drive Using Evolutionary Algorithms. *IEEE/ASME Transactions on Mechatronics (2001)*, 6(2), 149-154
- [12] Kamiński M. Zastosowanie algorytmu BAT w optymalizacji obliczeń adaptacyjnego regulatora stanu układu dwumasowego. *Przegląd Elektrotechniczny*, 93(2017), nr 1, 300-304
- [13] Chaoui H., Sicard P., Lakhsasi A., Schwarz H. Neural network based model reference adaptive control structure for a flexible joint with hard nonlinearities. *IEEE International Symposium on Industrial Electronics (2004)*, 271-276
- [14] Kabziński, J., Mosiołek, P. Adaptacyjne sterowanie dwumasowego układu napędowego z nieliniową charakterystyką sztywności. *Przegląd Elektrotechniczny*, 03/2018, 49-54
- [15] Zawirski K., Pajchrowski T., Nowopolski K. Application of adaptive neural controller for drive with elastic shaft and variable moment of inertia. *2015 17th European Conference on Power Electronics and Applications (EPE'15 ECCE-Europe) (2015)*, 1-10
- [16] Diao S., Sun W., Su S.F., Xia J. Adaptive Fuzzy Event-Triggered Control for Single-Link Flexible-Joint Robots with Actuator Failures. *IEEE Transactions on Cybernetics (2022)*, 52(8), 7231-7241
- [17] Kamiński M., Orłowska-Kowalska T. Clustering in optimization of RBF-based neural estimators for the drive system with elastic joint. *IEEE International Symposium on Industrial Electronics (2011)*, 1907-1911
- [18] Żychlewicz M., Stanisławski R., Kamiński M. Grey Wolf Optimizer in Design Process of the Recurrent Wavelet Neural Controller Applied for Two-Mass System. *Electronics (2022)*, 11(2), 177-199
- [19] Zawiaślak, R. Weryfikacja wrażliwości obserwatora zredukowanego z kompensacją nieliniowości na niedokładną identyfikację parametrów silnika bezszczotkowego, *Przegląd Elektrotechniczny*, 7/2020, 97-102
- [20] Luczak D., Pajchrowski T. Application of Adaptive Neural Controller and Filter Tune for Multi-Mass Drive System. *20<sup>th</sup> European Conference on Power Electronics and Applications (EPE'18 ECCE Europe) (2018)*, 1-9
- [21] Sleszycki K., Wrobel K., Szabat K., Katsura S. Parameter Identification of the Two-Mass System with the help of Multi-layer Estimator. *IEEE 30<sup>th</sup> International Symposium on Industrial Electronics (ISIE) (2021)*, 1-6
- [22] Brock S., Luczak D., Nowopolski K., Pajchrowski T., Zawirski K. Two Approaches to Speed Control for Multi-Mass System with Variable Mechanical Parameters. *IEEE Transactions on Industrial Electronics (2016)*, 64(4), 3338-3347
- [23] Kamiński M. Neural estimators of two-mass system optimized using the Levenberg-Marquardt training and genetic algorithm. *21<sup>st</sup> International Conference on Methods and Models in Automation and Robotics (MMAR) (2016)*, 559-564
- [24] Kamiński M., Orłowska-Kowalska T. Application of neural network with adaptive interaction for speed control of the drive system with elastic joint. *IEEE International Symposium on Industrial Electronics (2013)*, 1-6
- [25] Zhang R., Tong C. Torsional Vibration Control of the Main Drive System of a Rolling Mill Based on an Extended State Observer and Linear Quadratic Control. *Journal of Vibration and Control (2006)*, 12(3), 313-327
- [26] Bishop Ch.M. *Neural Networks for Pattern Recognition*, Oxford University Press, USA, 1996
- [27] Ren H.P., Jiao S.S., Wang X., Li J. Adaptive RBF Neural Network Control Method for Pneumatic Position Servo System. *IFAC – PapersOnLine (2020)*, 53(2), 8826-8831
- [28] Xu T., Liu J., Huang C., Sun T., Wu X. Discrete-Time Optimal Control of Miniature Helical Swimmers in Horizontal Plane. *IEEE Transactions on Automation Science and Engineering (2022)*, 19 (3), 2267-2277