

# Adaptacyjny-neuronowy obserwator Luenbergera zastosowany w estymacji zmiennych stanu układu dwumasowego

**Streszczenie.** W publikacji przedstawiono obserwator Luenbergera współpracujący z modelem jednokierunkowej sieci neuronowej. Zastosowany model steruje parametrami determinującymi właściwości dynamiczne klasycznego obserwatora. Celem jest redukcja wzmocnień szumów pomiarowych, obserwowanych w stanach ustalonych przebiegów oraz większa precyzja estymacji w stanach przejściowych. Opracowany układ zaimplementowano w celu odtwarzania zmiennych stanu układu napędowego z połączeniem elastycznym.

**Abstract.** In this article the Luenberger observer cooperating with feedforward neural network is described. Applied model controls parameters shaping dynamics properties of classical observer. The main goal is elimination of measurement noises, observed in transients during steady states and higher precision of estimation while transient states. Designed system was implemented for state variables estimation of drive with elastic joint. (Adaptive-neural Luenberger observer applied in state variables estimation of two-mass system).

**Słowa kluczowe:** sieć neuronowa, adaptacja parametrów, obserwator Luenbergera, układ dwumasowy.

**Keywords:** neural network, adaptation of parameters, the Luenberger observer, two-mass system.

doi:10.12915/pe.2014.06.15

## Wstęp

Estymacja trudnodostępnych sygnałów jest jednym z głównych trendów badań związanych z napędem elektrycznym [1]-[4]. Eliminacja czujników pomiarowych umożliwia redukcję kosztów realizacji napędu, a także zmniejsza prawdopodobieństwo występowania uszkodzeń struktury. Poza tym w wielu rzeczywistych aplikacjach instalacja czujników pomiarowych jest trudna do wykonania.

W zastosowaniach przemysłowych można spotkać wiele przykładów napędów z elastycznym wałem: taśmociągi [5], mechanizmy maszyn papierniczych [6], manipulatory stosowane w medycynie [7], napęd robotów [8], itd. W wyniku występowania skończonej sztywności elementów łączących w przebiegach zmiennych stanu obserwowane są oscylacje utrudniające precyzyjne sterowanie prędkością napędu. Jednym z efektywnych rozwiązań, stosowanych w celu tłumienia drgań skrętnych napędu z połączeniem sprężystym, jest rozwinięcie klasycznych struktur sterowania, polegające na wprowadzaniu dodatkowych sprzężeń zwrotnych od zmiennych stanu charakterystycznych dla układu napędowego z połączeniem sprężystym.

W celu uzyskania wymaganych informacji dotyczących struktury sterowania stosowane są układy umożliwiające obliczanie wymaganych zmiennych stanu na podstawie sygnałów dostępnych pomiarowo. Metody odtwarzania zmiennych stanu napędu dwumasowego można podzielić na dwie główne grupy [9]: metody algorytmiczne oraz metody wykorzystujące algorytmy sztucznej inteligencji. Wśród metod algorytmicznych najistotniejszymi układami są: obserwator Luenbergera [10], [11] oraz filtr Kalmana [12]. Jednak dokładność estymacji za pomocą wymienionych metod algorytmicznych jest zależna od precyzyjnej informacji o modelu matematycznym oraz parametrach obiektu. Wykorzystanie metod sztucznej inteligencji (np. sieci neuronowych) umożliwia precyzyjną estymację zmiennych stanu napędu dwumasowego, jednak najczęściej problematyczny jest proces projektowania takich układów oraz wymagana jest znaczna moc obliczeniowa [13], [14].

Niniejszy referat dotyczy obserwatora Luenbergera zastosowanego dla napędu z elastycznym wałem. Model obserwatora jest oparty o równania układu dwumasowego. Wzmocnienia estymatora mogą być wyznaczone analitycznie, np. z wykorzystaniem metody rozłożenia biegunów równania charakterystycznego [11], [15]. W takim przypadku dynamika odtwarzanych przebiegów jest zależna

od parametrów definiowanych na etapie projektowania – miary szybkości obserwatora oraz współczynnika tłumienia. Problematycznym staje się zdefiniowanie zadawanych wartości wpływających na dynamikę, szczególnie szybkości obserwatora [10]. Szybszy obserwator umożliwia uzyskanie lepszej dokładności estymacji zmiennych stanu, szczególnie w stanach przejściowych. Jednak w takim przypadku zakłócenia obliczeniowe oraz szumy pomiarowe są istotnie wzmacniane. W artykule zaproponowano metodę wyznaczania powyższych parametrów realizowaną za pomocą sieci neuronowej. W tym celu zastosowano model sieci jednokierunkowej, w której współczynniki wagowe uaktualniane są on-line w trakcie pracy napędu. Należy zaznaczyć dodatkową zaletę implementacji sieci neuronowej z zastosowanym trybem obliczeń jej parametrów. W przeciwieństwie do modeli trenowanych off-line, nie występuje w tym przypadku problem zbierania danych treningowych oraz złożonej optymalizacji struktury sieci. Niniejsza modyfikacja obserwatora Luenbergera stanowi oryginalne rozwiązanie w zastosowaniu dla napędu z połączeniem sprężystym.

## Neuronowy obserwator Luenbergera

Proponowany obserwator Luenbergera współpracujący z siecią neuronową testowano w zadaniu odtwarzania zmiennych stanu układu napędowego z połączeniem sprężystym. W układzie regulacji prędkości napędu dwumasowego zastosowano regulator stanu. Szczegóły dotyczące obiektu: maszyn elektrycznych połączonych elastycznym wałem, struktury sterowania oraz metodyki projektowania przedstawiono w publikacji [9]. Przyjęto następujące wartości parametrów układu dwumasowego:  $T_1=T_2=203\text{ms}$  oraz  $T_c=2,6\text{ms}$ .

W niniejszym rozdziale opisano adaptacyjny obserwator Luenbergera współpracujący z modelem neuronowym. Obserwowany obiekt można opisać za pomocą równań stanu:

$$(1-2) \quad \begin{aligned} \frac{d}{dt} \mathbf{x}(t) &= \mathbf{A} \mathbf{x}(t) + \mathbf{B} \mathbf{u}(t) \\ \mathbf{y}(t) &= \mathbf{C} \mathbf{x}(t) \end{aligned}$$

gdzie:  $\mathbf{x}(t)$ -wektor stanu,  $\mathbf{A}$ -macierz stanu,  $\mathbf{B}$ -macierz sterowań,  $\mathbf{C}$ -macierz wyjść,  $\mathbf{u}$ -macierz sygnałów wejściowych,  $\mathbf{y}$ -macierz sygnałów wyjściowych.

Wektor stanu układu zawiera prędkości: silnika oraz obciążenia, a także momenty: skrętny oraz obciążenia.

Jedyną zmienną stanu macierzy wejściowej obserwatora Luenbergera jest moment elektromagnetyczny. Estymowana prędkość silnika napędowego jest wielkością wyjściową. Przy takich założeniach równanie opisujące obserwator Luenbergera można przedstawić następująco:

$$(3-4) \quad \begin{aligned} \frac{d}{dt} \hat{\mathbf{x}}(t) &= \mathbf{A}\hat{\mathbf{x}}(t) + \mathbf{B}\mathbf{u}(t) + \mathbf{L}[\mathbf{y}(t) - \hat{\mathbf{y}}(t)] \\ \hat{\mathbf{y}}(t) &= \mathbf{C}\hat{\mathbf{x}}(t) \end{aligned}$$

gdzie:  $\hat{\mathbf{x}} = [\omega_{1e} \quad \omega_{2e} \quad m_{se} \quad m_{1e}]^T$ ,  $\mathbf{u} = m_e$ ,  $\mathbf{y} = \omega_1$ ,

$$\hat{\mathbf{y}} = \omega_{1e},$$

$$\mathbf{A} = \begin{bmatrix} 0 & 0 & -\frac{1}{T_1} & 0 \\ 0 & 0 & \frac{1}{T_2} & -\frac{1}{T_2} \\ \frac{1}{T_c} & -\frac{1}{T_c} & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}, \mathbf{B} = \begin{bmatrix} \frac{1}{T_1} \\ 0 \\ 0 \\ 0 \end{bmatrix},$$

$$\mathbf{C} = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}^T, \mathbf{L} = \begin{bmatrix} h_1 \\ \frac{T_1}{h_3} \\ T_2 \\ \frac{h_2}{T_c} \\ h_4 \end{bmatrix},$$

$\mathbf{L}$  jest macierzą wzmocnień obserwatora,  $h_1-h_4$  współczynniki korekcyjne.

W celu wyznaczenia współczynników korekcyjnych, według teorii sterowania modalnego, przyjmuje się zależność:

$$(5) \quad p(s) = \det(s\mathbf{I} - (\mathbf{A} - \mathbf{L} \cdot \mathbf{C})),$$

zgodnie z którą możliwe jest wyznaczenie wielomianu charakterystycznego obserwatora:

$$(6) \quad p(s) = s^4 + \frac{h_1}{T_1}s^3 + \frac{1}{T_c} \left( \frac{1}{T_2} + \frac{1-h_2}{T_1} \right) s^2 + \frac{h_1+h_3}{T_1T_2T_c}s - \frac{h_4}{T_1T_2T_c}.$$

W dalszych obliczeniach odpowiednie współczynniki równania (6) porównywane są z elementami wielomianu żądanego:

$$(7) \quad m(s) = s^4 + s^3(4dp) + s^2(2p^2 + 4d^2p^2) + s(4dp^3) + p^4$$


, gdzie:  $d$  – współczynnik tłumienia obserwatora;  $p$  – pulsacja rezonansowa obserwatora. W ten sposób uzyskiwany jest układ równań, po rozwiązaniu którego otrzymywane są zależności:

$$(8-11) \quad \begin{aligned} h_1 &= 4dpT_1 \\ h_2 &= \frac{T_1}{T_2} + 1 - T_1T_c(4d^2 + 2)p^2 \\ h_3 &= 4dpT_1(T_cT_2p^2 - 1) \\ h_4 &= -T_1T_2T_cp^4 \end{aligned}$$

Parametry  $p$  oraz  $d$  wpływają na właściwości dynamiczne układu. Najczęściej wartości tych parametrów są stałe. Zakłada się, że obserwator powinien być znacznie szybszy od obiektu (miara szybkości powinna być 2 do 5-krotnie większa od pulsacji rezonansowej układu sterowania) [10]. W rzeczywistości ich dobór jest kompromisem pomiędzy dużą dynamiką obserwatora a brakiem zakłóceń odtwarzanych sygnałów. Można zatem założyć, że w idealnym przypadku korzystne jest zwiększanie dynamiki dla większych wartości błędów estymacji (najczęściej w stanach przejściowych napędu). Natomiast w stanach ustalonych dynamika obserwatora, a zatem wzmacnianie zakłóceń powinna być zredukowana. W celu graficznego przedstawienia powyższej opisanych zależności wykreślony został przykładowy wpływ współczynników  $p$  oraz  $d$  na dokładność odtwarzania wybranej zmiennej stanu układu dwumasowego (rys.1). Błędy estymacji, w niniejszym artykule, wyznaczano za pomocą wzoru:

$$(12) \quad Err = \frac{\sum_{i=1}^n |x_i - \hat{x}_i|}{n} \cdot 100$$

gdzie:  $x_i$  – wartość rzeczywista,  $\hat{x}_i$  – wartość estymowana,  $n$  – liczba próbek.

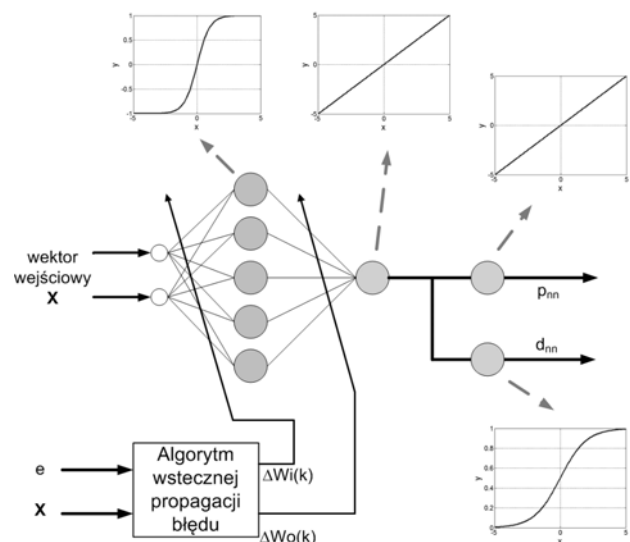


Rys.1. Zależność błędu odtwarzania prędkości obciążenia od dynamiki klasycznego obserwatora Luenbergera (parametrów  $p$  oraz  $d$ )

Na rysunku 1 można zaobserwować zależność precyzji działania obserwatora Luenbergera od zadawanych parametrów. Istnieje optymalna wartość obu współczynników decydująca o optymalnych wzmocnieniach sygnałów oraz dynamice obserwatora Luenbergera. W powyższych badaniach przyjęto stałą wartość  $p$  oraz  $d$  dla kolejnych testów. W niniejszym opracowaniu zaproponowano aplikację sieci neuronowej do wyznaczania szybkości obserwatora Luenbergera  $p_{nn}$  oraz współczynnika tłumienia  $d_{nn}$ . Punkt pracy obserwatora jest zatem adaptowany on-line, wartości parametrów  $d_{nn}$  oraz  $p_{nn}$  zmieniają się w zależności od błędów. Założono, że w przeciwieństwie do wcześniej analizowanego przypadku, sieć neuronowa może poszukiwać optymalnej dynamiki dla różnych stanów pracy napędu.

Podstawowy element sieci neuronowej realizuje skalowanie swoich sygnałów wejściowych zgodnie z wartościami odpowiadających im współczynników wagowych. Następnie suma uzyskanych wyników stanowi wejście funkcji aktywacji. Strukturę sieci tworzy odpowiednie ułożenie opisanych jednostek w warstwy.

Topologię sieci neuronowej zastosowanej do optymalizacji obserwatora Luenbergera zaprezentowano na rysunku 2.



Rys.2. Model sieci neuronowej (trenowanej on-line) zastosowanej w adaptacji parametrów obserwatora Luenbergera

Przetwarzany wektor wejściowy  $X$  zawiera dwa wejścia, do których podawana jest informacja o błędzie definiowanym zgodnie z zależnością:

$$(13) \quad e = |\omega_1 - \omega_{1e}|$$

W celu poprawy przetwarzania przebiegów dynamicznych w wektorze  $X$  założono dodatkowo człony inercyjne pierwszego rzędu. W sieci neuronowej poza głównym torem przetwarzania równolegle wyznaczane są poprawki współczynników wagowych. Wartość (13) jest również wykorzystywana bezpośrednio do obliczeń algorytmu adaptacji. W każdej iteracji obliczeń związanych z całą strukturą sterowania wprowadzana jest adaptacja wag:

$$(14) \quad w_{ij}(k+1) = w_{ij}(k) - \Delta w_{ij}$$

gdzie:  $w_{ij}$  – współczynnik wagowy pomiędzy  $i$ -tym oraz  $j$ -tym neuronem w  $k$ -tej iteracji. Obliczenia części adaptacyjnej są wykonywane według algorytmu wstecznej propagacji błędów [16]. Aktualizacja poszczególnych współczynników sieci neuronowej jest realizowana według zależności:

$$(15) \quad \Delta w_{ij} = \alpha \delta_j x_{ij}$$

gdzie:  $\alpha$  – współczynnik uczenia,  $x_{ij}$  –  $i$ -te wejście  $j$ -tego neuronu,  $\delta_j$  – propagowany w strukturze sieci błąd oraz pochodna funkcji aktywacji.

Parametr  $\alpha$  we wzorze (15) wpływa na szybkość działania algorytmu optymalizacyjnego. Analizowany model zawiera jedną warstwę ukrytą zawierającą pięć neuronów z sigmoidalnymi funkcjami aktywacji oraz jedno wyjście. Wartość  $\delta_j$  w równaniu (15), dla wag pomiędzy wejściami oraz warstwą ukrytą może być opisana równaniem:

$$(16) \quad \delta_j = f'_j \delta_o w_{jo}$$


$f'_j$  – pochodna funkcji aktywacji  $j$ -tego neuronu warstwy ukrytej,  $w_{jo}$  – wagi pomiędzy warstwą ukrytą a wyjściem. Dla warstwy wyjściowej zawierającej pojedynczy neuron liniowy  $\delta_j = \delta_o$ :

$$(17) \quad \delta_o = o - y$$

gdzie:  $o$  – pożądana wartość sygnału wyjściowego,  $y$  – aktualna wartość wyjściowa sieci neuronowej.


## Wyniki badań

Wszystkie badania przedstawione w artykule wykonano dla rzeczywistych przebiegów zarejestrowanych na stanowisku badawczym. Obliczenia przeprowadzono w programie Matlab\Simulink. Sygnałami wejściowymi całej struktury neuronowej obserwatora Luenbergera są moment elektromagnetyczny  $m_e$  oraz prędkość silnika napędzającego  $\omega_1$ . Przebiegi tych zmiennych stanu przedstawiono na rysunku 3.



Rys.3. Wejściowe zmienne stanu neuronowego obserwatora Luenbergera

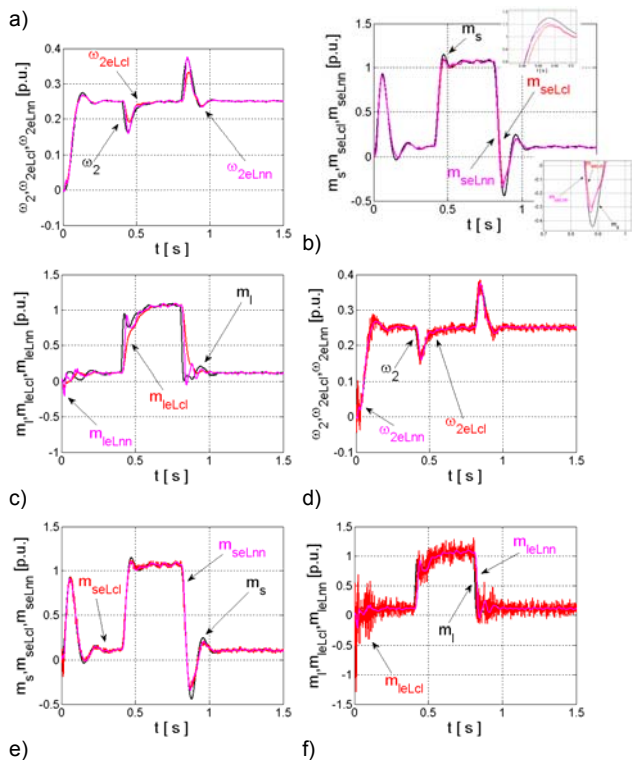
Zgodnie z założeniem wartości  $d_{nn}$  oraz  $p_{nn}$  obserwatora Luenbergera są adaptowane w trakcie pracy napędu. Przykładowe przebiegi tych sygnałów przedstawiono na rysunku 4. Model neuronowy wpływa na właściwości dynamiczne układu odtwarzającego. W stanach przejściowych, kiedy błędy wzrastają współczynnik tłumienia  $d_{nn}$  nieznacznie maleje, jednocześnie  $p_{nn}$  znacząco wzrasta. Po ustaleniu prędkości na poziomie zadanym następuje sytuacja przeciwna.



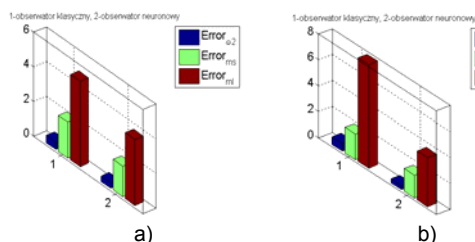
Rys.4. Przebiegi  $p_{nn}$  oraz  $d_{nn}$  neuronowego obserwatora Luenbergera

Wstępne testy dotyczą przypadku, w którym w obserwatorze klasycznym ( $Lcl$ ) założono pulsację rezonansową równą wartości dwukrotnie większej niż w regulatorze stanu ( $\omega_b$ ) –  $p=2\omega_b$ . Wszystkie badania w artykule wykonano dla współczynnika tłumienia klasycznego obserwatora Luenbergera:  $d=1$ . Zmniejszenie tej wartości wpływa na nieznaczne zwiększenie dynamiki obserwatora, jednak poziom zakłóceń jest zbyt duży. Poza tym zaobserwowano, że na dynamikę układu odtwarzającego większy wpływ ma parametr  $p$ . Na przedstawionych przebiegach (rys.5a-c) obserwowane jest rozpędzanie napędu do prędkości równej 25% wartości nominalnej, po ustaleniu prędkości następują przełączenia momentu obciążenia. Wyniki estymacji prezentują bardzo wysoką dokładność odtwarzania analizowanych zmiennych stanu za pomocą neuronowego obserwatora Luenbergera ( $Lnn$ ). Szczególna poprawa działania jest widoczna w stanach przejściowych, jednocześnie w stanach ustalonych układ nie wzmacnia zakłóceń.

Następnie zwiększono dynamikę klasycznego obserwatora Luenbergera poprzez zamianę wartości parametru  $p=5\omega_b$ . Przebiegi estymat poszczególnych zmiennych stanu są znacznie szybsze, jednak zaszumienie sygnałów jest bardzo znaczące (rys.5d-f). Jest to szczególnie istotne w praktycznych implementacjach gdzie sygnały estymowane są wykorzystywane w dalszych obliczeniach (np. w regulatorach).



Rys.5. Przebiegi, rzeczywiste i estymowane (przez klasyczny Lcl oraz neuronowy Lnn obserwator Luenbergera) prędkości obciążenia  $\omega_2$  (a,d), momentu skrętnego  $m_s$  (b,e) oraz momentu obciążenia  $m_1$  (c,f) - dla  $p=2\omega_b$  (a-c) oraz  $p=5\omega_b$  (d-f)



Rys.6. Zestawienie błędów estymacji poszczególnych zmiennych stanu dla porównywanych układów przy różnej szybkości klasycznego obserwatora Luenbergera -  $p=2\omega_b$  (a) oraz  $p=5\omega_b$  (b)

Na diagramach zamieszczonych na rysunku 6 przedstawiono wartości błędów estymacji klasycznego oraz neuronowego obserwatora Luenbergera. Wartości dotyczą różnych szybkości klasycznego układu (analizowanych powyżej) oraz adaptacyjnych parametrów neuronowego obserwatora (rys.4). Wszystkie zmienne stanu w obu testach są dokładniej estymowane za pomocą neuronowego obserwatora Luenbergera.

## Podsumowanie

W przedstawionym artykule zaproponowano rozwinięcie klasycznego obserwatora Luenbergera. Sieć neuronową trenowaną on-line zastosowano w sterowaniu dynamiką klasycznej wersji obserwatora. Zadaniem analizowanego układu była estymacja zmiennych stanu napędu z połączeniem sprężystym. Uzyskano bardzo wysoką dokładność estymacji prędkości obciążenia, momentu skrętnego oraz momentu obciążenia. Wprowadzenie opisywanej modyfikacji umożliwia poprawę pracy klasycznego obserwatora Luenbergera. Poprzez możliwość ograniczenia sygnałów z modelu neuronowego stabilność obserwatora jest zagwarantowana i możliwa do

udowodnienia w sposób analityczny. Opisywany neuronowy obserwator Luenbergera może być zastosowany w różnych strukturach napędowych, w których wykorzystywane będą odmienne typy silników, metodyka projektowania jest analogiczna. Warto podkreślić, że opisywane rozwiązanie wprowadza rzeczywistą optymalizację. Implementacja sprzętowa proponowanej postaci obserwatora Luenbergera nie jest skomplikowana.

## LITERATURA

- [1] Erenturk K., Nonlinear two-mass system control with sliding-mode and optimised proportional-integral derivative controller combined with a grey estimator, *IET Control Theory and Applications*, 2 (2008), n.7, 635-642
- [2] Brock S., Deskur J., Janiszewski D., Muszyński R., Active damping of torsional vibrations in servodrives, *Power Electronics and Electrical Drives. Selected Problems, Polish Academy of Sciences Electrical Engineering Committee, Edited by Teresa Orłowska-Kowalska*, Oficyna Wydawnicza Politechniki Wrocławskiej, (2007), 271-290
- [3] Pracownik A., Sieklucki G., Tondos M., Cyfrowy obserwator LQ w układzie 2-masowym, *Elektrotechnika i Elektronika*, 29 (2010), nr 1-2, 14-19
- [4] Dhaouadi R., Kubo K., Tobise M., Two-degree-of-freedom robust speed controller for high-performance rolling mill drives, *IEEE Transactions on Industry Applications*, 29 (1993), n.5, 919 - 926
- [5] Hace A., Jezernik K., Sabanovic A., Improved Design of VSS controller for a linear belt-driven servomechanism, *IEEE/ASME Transaction on Mechatronics*, 10 (2005), n. 4, 385-390
- [6] Valenzuela M. A., Bentley J. M., Lorenz R. D., Evaluation of torsional oscillations in paper machine sections, *IEEE Transaction on Industrial Applications*, 41 (2005), n.2, 493-501
- [7] Englert M., Trapp R., de Klerk R., Neural Control of a Nonlinear Elastic Two-Mass System, *Computational Intelligence, Theory and Applications, International Conference, 5th Fuzzy Days*, 1226 (1997), 553-553
- [8] Tomei P., A simple PD controller for robots with elastic joints, *IEEE Transactions on Automatic Control*, 36 (1991), n.10, 1208 - 1213
- [9] Szabat K., *Struktury sterowania elektrycznych układów napędowych z połączeniem sprężystym*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Seria: Monografie, Oficyna Wydawnicza Politechniki Wrocławskiej, 61 (2008), nr 19
- [10] Szabat K., Model obserwatora zmiennych stanu dla układu z nieliniowym wałem mechanicznym, *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej. Studia i Materiały*, 63 (2009), nr 29, 355-368
- [11] Paul P. Muszyński R., Zmodyfikowany obserwator w układzie napędowym z połączeniem sprężystym, *Materiały konferencji SENE'03*, (2003), 399-404
- [12] Szabat K., Orłowska-Kowalska T., Application of the Kalman Filters in the Self-Commissioning High-Performance Drive System with an Elastic Joint, *Kalman Filter Recent Advances and Applications*, book edited by Victor M. Moreno and Alberto Pigazo, (2009), 421-437
- [13] Orłowska-Kowalska T., Kaminski M., Application of the OBD method for optimization of neural state variable estimators of the two-mass drive system, *Neurocomputing*, 72 (2009), n.13-15, 3034-3045
- [14] Orłowska-Kowalska T., Kaminski M., FPGA Implementation of the Multilayer Neural Network for the Speed Estimation of the Two-Mass Drive System, *IEEE Transactions on Industrial Informatics*, 7 (2011), n.3, 436-445
- [15] Gierlotka K., *Układy sterowania napędów elektrycznych z elementami sprężystymi*, Zeszyt Naukowy Politechniki Śląskiej, nr 1181, Gliwice, 1992
- [16] Bishop M.C., *Neural Networks for Pattern Recognition*, Oxford University Press, (1996)

**Autor:** dr inż. Marcin Kamiński, 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)