

Estymacja stanu układu dwumasowego z wykorzystaniem konwolucyjnej sieci neuronowej

State estimation of a two-mass system using a convolutional neural network

Streszczenie. W pracy zaprezentowano zastosowanie konwolucyjnej sieci neuronowej do estymacji zmiennych stanu układu dwumasowego. Dobrano odpowiednią strukturę sieci. Zaproponowaną sieć nauczono za pomocą wektorów uczących uzyskanych w badaniach symulacyjnych. Wytrenowana sieć została przetestowana w warunkach symulacyjnych jak i eksperymentalnych w formie pracy off-line względem układu sterowania.

Abstract. In this paper, the application of a convolutional neural network to the estimation of the state variables of a dual mass system is presented. A suitable network structure was selected. The constructed network was then learned using learning vectors obtained from simulation studies. The trained network was tested under simulation conditions and experimentally as an off-line operation in the control system.

Słowa kluczowe: konwolucyjne sieci neuronowe, estymacja zmiennych stanu, układ dwumasowy.

Keywords: convolutional neural networks, state estimation, two mass system.

Wstęp

W nowoczesnych układach napędowych kluczowymi zadaniami są: niezawodne sterowanie, dynamiczna reakcja układu na zadawane sygnały oraz dostęp do wartości wewnętrznych zmiennych stanu [1,2]. Jest to szczególnie ważne w systemach o złożonych strukturach mechanicznych, gdy silnik połączony jest z maszyną obciążającą za pomocą długiego lub elastycznego wału. W układach dwumasowych, występujących między innymi w napędach walcarek [3], ramion robotów [4] czy turbin wiatrowych [5] zaobserwować można oscylacje zmiennych stanu spowodowane skończoną sztywnością elementów mechanicznych. Przy zwiększonej dynamice działania układów, elastyczność połączenia mechanicznego ujawnia się w coraz szerszej grupie napędów, takich jak: napędy dysków twardych, czy też napędy stosowane w elektromobilności. Drgania wynikające z rozbieżności między prędkościami kątowymi silnika oraz obciążenia negatywnie wpływają na proces produkcyjny, a w skrajnych przypadkach prowadzić mogą do utraty stabilności, a nawet uszkodzeń układu.

Uwzględniając powyższe aspekty, w układach dwumasowych, konieczne staje się zastosowanie bardziej złożonych struktur sterowania. W literaturze znaleźć można rozwiązania stosujące: regulatory stanu [6], regulatory odporne [7], kaskadowe regulatory PI z dodatkowymi pętami sprzężenia zwrotnego [1], regulatory adaptacyjne [4,8,9], algorytmy FDC [10], nowoczesne, zaawansowane struktury sterowania wykorzystujące metody sztucznej inteligencji [11,12] lub algorytmy predykcyjne [13]. Struktury te umożliwiają skuteczne tłumienie drgań skrętnych powstających w układzie, zwykle jednak wymagają dokładnej znajomości parametrów modelu układu oraz estymowania w czasie rzeczywistym niemierzalnych lub trudno mierzalnych zmiennych stanu takich jak moment skrętny czy prędkość kątowa maszyny obciążającej.

W celu estymacji stanu obiektu stosuje się różnego rodzaju algorytmy. Pierwszą grupą metod umożliwiających estymowanie zmiennych stanu są metody algorytmiczne (oparte na znajomości modelu obiektu), do których zaliczają się między innymi obserwatory zakłóceń [1], obserwatory Luenbergera [14, 15], estymatory z przesuwym oknem (MHE) [16] oraz filtry Kalmana [17]. W klasycznym rozwiązaniu, obserwator zakłóceń pozwala estymować wyłącznie moment skrętny. W przypadku obserwatorów Luenbergera, estymowane parametry można wyznaczyć za

pomocą analitycznych zależności. Dokładność uzyskanej estymacji zależy od skomplikowania zaproponowanego modelu matematycznego układu napędowego, dokładności pomiarów wykorzystywanych wielkości oraz stopnia znajomości parametrów modelu. Nieliniowe filtry Kalmana z kolei umożliwiają estymowanie zmiennych stanu, nawet przy występowaniu zakłóceń pomiarowych lub parametrycznych, jednak wymagają dużej ilości obliczeń podczas wyznaczania macierzy kowariancji.

Drugą grupę stanowią układy wykorzystujące sztuczne sieci neuronowe, które nie potrzebują do swojego działania informacji o strukturze modelu matematycznego obiektu oraz dokładnej znajomości jego parametrów. Cecha ta powoduje, że są one coraz chętniej i częściej wykorzystywane w zastosowaniach przemysłowych. Układy oparte na sieciach neuronowych w napędach elektrycznych wykorzystywane są do diagnostyki [18,19, 20], sterowania [21] oraz estymacji zmiennych stanu [22, 23,24].

W ostatnich latach szczególnie warte uwagi są konwolucyjne sieci neuronowe (ang. CNN - Convolutional Neural Network), które początkowo były wykorzystywane do przetwarzania obrazów zapisanych za pomocą trójwymiarowych macierzy. Ich użyteczność wykracza jednak poza analizę obrazów i obejmuje także, takie zastosowania jak: rozpoznawanie mowy, przetwarzanie języka naturalnego czy analizę wektorów danych lub szeregów czasowych [20,25].

Główna różnica między w pełni połączonymi warstwami (ang. FC – Fully Connected), stosowanymi w wielowarstwowych sieciach perceptronowych (ang. MLP – MultiLayer Perceptron) a warstwami konwolucyjnymi polega na sposobie połączeń między neuronami w poszczególnych warstwach. W przypadku warstw w pełni połączonych każdy neuron kolejnej warstwy jest połączony z każdym neuronem poprzedniej warstwy, powodując globalne przetwarzanie danych. Warstwy konwolucyjne charakteryzują się występowaniem lokalnych połączeń – neurony połączone są tylko z podzbiorem neuronów poprzedniej warstwy będących w zasięgu pola recepcyjnego zależnego od parametrów filtra (ang. kernel). Takie lokalne połączenie ułatwia wykrywanie wzorców w określonych fragmentach danych wejściowych oraz znacznie zmniejsza liczbę parametrów sieci dzięki współdzieleniu wag. W rezultacie konwolucyjne sieci neuronowe mogą zawierać głębsze architektury o niższych wymaganiach obliczeniowych

w porównaniu do wielowarstwowych sieci perceptronowych, jednocześnie skutecznie wychwytyjąc cechy wyższego rzędu z sygnału wejściowego.

W takiej sytuacji sądzić można, że właściwości generalizujące całych sieci lub ich początkowych warstw umożliwiają zastosowanie mechanizmu uczenia transferowego (*ang. transfer learning*), który pozwala na prawidłowe działanie sieci neuronowej z danymi wejściowymi uzyskanymi z innego modelu (np. symulacyjnego) lub z innego obiektu (np. z innego stanowiska) [26]

W niniejszej pracy zaprezentowany jest estymator prędkości maszyny roboczej oraz momentu skrętnego wykorzystujący mechanizm uczenia transferowego w konwolucyjnych sieciach neuronowych uczonych wyłącznie na danych uzyskanych z badań symulacyjnych. Wielkościami wejściowymi sieci są: prędkość silnika ω_1 oraz moment elektromagnetyczny m_e , natomiast wielkościami wyjściowymi są moment skrętny m_s oraz prędkość maszyny roboczej ω_2 .


Na początku przedstawiony został model matematyczny wykorzystany do badań symulacyjnych, następnie opisano strukturę sieci oraz parametry treningu, po czym omówione zostały wyniki badań przeprowadzonych na obiekcie rzeczywistym.

Model matematyczny układu dwumasowego

Podczas badań symulacyjnych wykorzystano liniowy model układu dwumasowego z bezinercyjnym połączeniem sprężystym. W podejściu takim zakłada się, że moment bezwładności sprężystego wału łączącego dwie wirujące masy dodawany jest po połowie do momentów bezwładności tych mas. Dla uproszczenia pominięto również wpływ tarcia wiskotycznego oraz tłumienia wału. Model matematyczny w zapisie macierzowym przedstawia równanie 1 [1] a odpowiadający mu schemat ideowy pokazano na rysunku 1.

$$(1) \frac{d}{dt} \begin{bmatrix} \omega_1(t) \\ \omega_2(t) \\ m_s(t) \end{bmatrix} = \begin{bmatrix} 0 & 0 & \frac{-1}{T_1} \\ 0 & 0 & \frac{1}{T_2} \\ \frac{1}{T_c} & \frac{-1}{T_c} & 0 \end{bmatrix} \begin{bmatrix} \omega_1(t) \\ \omega_2(t) \\ m_s(t) \end{bmatrix} + \begin{bmatrix} \frac{1}{T_1} \\ 0 \\ 0 \end{bmatrix} [m_e] + \begin{bmatrix} 0 \\ \frac{-1}{T_2} \\ 0 \end{bmatrix} [m_L]$$

gdzie: ω_1, ω_2 – prędkości silnika i maszyny roboczej, m_e, m_s, m_L – odpowiednio momenty: elektromagnetyczny, skrętny wału, obciążenia, T_1, T_2 – mechaniczne stałe czasowe silnika i maszyny, T_c – stała czasowa elementu sprężystego.



Rys. 1. Schemat układu dwumasowego

Struktura sterowania

Strukturę sterowania (rys. 2) oparto na regulatorze IP z dwoma dodatkowymi sprzężeniami zwrotnymi (od momentu skrętnego i od różnicy prędkości). Współczynniki wzmocnień poszczególnych torów regulacji dobrano z wykorzystaniem metody rozłożenia biegunów za pomocą wzorów (2)-(5) [1].

$$(2) k_I = T_1 T_2 T_c \omega_r^4$$


$$(3) k_p = 4 T_1 T_2 T_c \xi_r \omega_r^3$$

$$(4) k_2 = \frac{1}{\omega_r^2 T_2 T_c} - 1$$

$$(5) k_1 = \frac{T_1 (4 \xi_r^2 - k_2)}{T_2 (1 + k_2)} - 1$$


gdzie: ω_r – pulsacja rezonansowa układu zamkniętego, ξ_r – współczynnik tłumienia.

W pracy przyjęto następujące wartości parametrów układu zamkniętego $\omega_r = 30 \text{ s}^{-1}$, $\xi_r = 0,7$. Założono również, że pętla generacji momentu jest zoptymalizowana i posiada pomijalne opóźnienie. W badaniach symulacyjnych moment elektromagnetyczny nie był ograniczany.



Rys. 2. Struktura sterowania


Sygnały sprzężeń zwrotnych prędkości pochodzą z czujników, natomiast moment skrętny odtwarzany jest przez prosty symulator, którego strukturę przedstawiono na rysunku 3. Proponowany estymator neuronowy pracuje poza pętlą sterowania.



Rys. 3. Schemat blokowy symulatora momentu skrętnego

Estymator neuronowy

Warstwa wejściowa sieci otrzymuje dwa wektory składające się z ostatnich 48 próbek wielkości wejściowych. Dane te zostają równolegle rozesłane do dwóch różnych warstw konwolucyjnych. Operacja konwolucji polega na obliczaniu iloczynów skalarnych między wagami filtra i odpowiadającymi im wartościami danych wejściowych znajdujących się w zasięgu pola recepcyjnego filtra. Schemat działania operacji konwolucji przedstawiony jest na rysunku 4.




Rys. 4. Schemat ideowy operacji konwolucji


Pierwsza z warstw charakteryzuje się parametrem kroku (*ang. stride*) wynoszącym dwa, który określa odległość między kolejnymi polami recepcyjnymi filtrów (rys. 5). Taki zabieg umożliwia zmniejszenie kolejnej warstwy i zredukowanie liczby operacji konwolucji przy zachowaniu

zdolności do przechwytywania lokalnych cech zawartych w sąsiadujących ze sobą neuronach.

Druga warstwa jest warstwą konwolucyjną dylatacyjną, która charakteryzuje się „rozszerzeniem” pola recepcyjnego filtrów poprzez wstawienie przerw między jego kolejne neurony (rys. 6). Pozwala to na przechwytywanie cech zawartych w długim horyzoncie czasowym bez zwiększania liczby parametrów i złożoności obliczeniowej.




Rys. 5. Wpływ parametru kroku na operację konwencji



Rys. 6. Wpływ parametru dylatacji na operację konwencji

Wyjścia obu warstw konwolucyjnych łączone są w głąb (w wymiarze kanału) w warstwie konkatencji (*ang. depth concatenation layer*) (rys. 7), co pozwala na połączenie zalet obu warstw – w wyniku operacji konwencji i konkatencji powstają mapy cech, które wykrywają zarówno wzorce lokalne jak i te o dłuższych zależnościach czasowych. Następnie dane są wyśrodkowane i znormalizowane w warstwie normalizacji wsadowej (*ang. batch normalization layer*) poprzez odjęcie od danych średniej z mini-grupy (*ang. mini-batch*) i podzieleniu przez odchylenie standardowe.



Rys. 7. Połączenie filtrów konwolucyjnych w warstwie konkatencji

Po obliczeniu wyjść sigmoidalnej funkcji aktywacji, dane przekazywane są ponownie do kolejnych warstw konwolucyjnej, normalizacji wsadowej i funkcji aktywacji. Wyjściową warstwą sieci jest warstwa w pełni połączona z dwoma neuronami wyjściowymi, która umożliwia estymację aktualnej wartości prędkości maszyny roboczej oraz momentu skrętnego. Dokładne parametry poszczególnych warstw oraz parametry treningu przedstawione zostały w tabeli 1, a struktura sieci na rysunku 8.


Dane wykorzystane do nauki sieci uzyskane zostały w badaniach symulacyjnych przeprowadzonych w środowisku MATLAB/Simulink. Obliczenia zostały wykonane z krokiem symulacji 500 μ s. Przebiegi zadanego sygnału prędkości oraz przyłożonego momentu obciążenia przedstawione zostały na rysunku 9.

W celu analizy właściwości generalizujących zaproponowanego rozwiązania uwzględniono możliwie szeroki zakres stanów, w jakich układ napędowy może się znajdować, tj. skokowe zmiany prędkości, skokowe zmiany


momentu obciążenia, nawroty, pracę z niską prędkością obrotową, pracę z prędkością znamionową. Wyniki symulacji przedstawione zostały na rysunku 10 i 11.

Tabel 1. Parametry warstw oraz treningu.


Parametr	Wartość parametru
Rozmiar filtrów warstwy konwolucyjnej	konwolucyjna 1: 1 x 7 konwolucyjna 2: 1 x 7 konwolucyjna 3: 1 x 5
Liczba filtrów w warstwie	konwolucyjna 1: 8 konwolucyjna 2: 8 konwolucyjna 3: 8
Rozmiar kroku warstwy konwolucyjnej	konwolucyjna 1: 1 x 2 konwolucyjna 2: 1 x 1 konwolucyjna 3: 1 x 2
Uzupełnianie zerami (<i>ang. padding</i>)	konwolucyjna 1: 'same' konwolucyjna 2: 0 konwolucyjna 3: 0
Człon wygładzający warstwy normalizacji wsadowej (ϵ)	0,001
Metoda uczenia	SGDM
Początkowy współczynnik uczenia	0,01
Liczba epok	30
Rozmiar macierzy trenującej	1 x 48 x 2 x 74954
Rozmiar macierzy walidującej	1 x 48 x 2 x 44954
Częstotliwość walidacji	700 iteracji
Wczesne zatrzymanie:	'validation patience' = 20 iteracji
Rozmiar minigrupy	32
Generowanie minigrup (<i>ang. shuffle</i>)	co epokę
Momentum	0,9
Harmonogram uczenia	wykładnicze co 10 epok
Funkcja straty	błąd średniokwadratowy
Ilość wyjść	2




Rys. 8. Struktura sieci



Rys. 9. Przebiegi sygnałów zadaných podczas uczenia (prędkości zadanej i momentu obciążenia)




Rys. 10. Przebiegi prędkości (silnika napędzającego, silnika obciążającego oraz referencyjna), wyniki symulacyjne, użyte w procesie uczenia sieci



Rys. 11. Przebiegi momentów (elektromagnetycznego, skrętnego i obciążenia), wyniki symulacyjne, użyte w procesie uczenia sieci


Przedstawioną strukturę sterowania przebadano w warunkach symulacyjnych w środowisku MATLAB/Simulink oraz z wykorzystaniem stanowiska laboratoryjnego przedstawionego na rysunku 12.




Rys. 12. Schemat ideowy stanowiska laboratoryjnego

Na stanowisku laboratoryjnym wykorzystano dwa silniki prądu stałego (oba o mocy 500W) połączone długim (600 mm) wałem o skończonej sztywności. Do obu silników podłączone były enkodery inkrementalne o rozdzielczości 36000 pulsów. Silnik napędowy zasilany był za pomocą mostka H. Zmiana momentu obciążenia odbywa się poprzez podłączenie i odłączenie uzwojeń silnika obciążającego do rezystora. Struktura regulacji zaimplementowana jest z wykorzystaniem karty pomiarowej dSpace 1103 oraz środowiska ControlDesk.

W ramach przeprowadzonych testów przebadano działanie opracowanej sieci w różnych warunkach pracy, w tym przy różnych prędkościach i momentach obciążenia. Na rysunkach 9 i 10 przedstawiono odpowiednio wyniki badań dla prędkości zadanej 0,2 i 0,7 [p.u.]. Schemat działania układu przewiduje zmianę prędkości z częstotliwością 0,2 Hz. Sekundę po nawrocie, na pół sekundy, załączany jest moment obciążenia. Na rysunkach przedstawiono: prędkość referencyjną, zmierzone prędkości silnika napędowego i obciążającego oraz estymowaną prędkość silnika obciążającego. Przedstawiono również przebiegi momentu elektromagnetycznego oraz momentów skrętnych estymowanych przez prosty symulator i sieć neuronową. Jak pokazano na rysunkach opracowana sieć neuronowa dość dobrze odtwarza zarówno prędkość maszyny roboczej jak i moment skrętny. W przebiegach obu zmiennych widoczne są dość duże poziomy oscylacje.



Rys. 13. Wyniki badań eksperymentalnych: a) prędkości silnika napędzającego (referencyjna i zmierzona) oraz silnika obciążającego (zmierzona i estymowana), b) momentów elektromagnetycznego i skrętnego (odtworzonego za pomocą symulatora i sieci konwolucyjnej), dla prędkości zadanej 0,2 [p.u.]



Rys. 14. Wyniki badań eksperymentalnych: a) prędkości silnika napędzającego (referencyjna i zmierzona) oraz silnika obciążającego (zmierzona i estymowana), b) momentów elektromagnetycznego i skrętnego (odtworzonego za pomocą symulatora i sieci konwolucyjnej), dla prędkości zadanej 0,7 [p.u.]

Przenoszą się one z przebiegu momentu elektromagnetycznego. W warunkach symulacyjnych przebieg momentu elektromagnetycznego nie jest tak zaszumiony jak w warunkach rzeczywistych. Rozwiązaniem w tym przypadku byłby odpowiedni filtr albo douczenie sieci z wykorzystaniem próbek z układu rzeczywistego. Można również nałożyć odpowiedni szum na sygnały uczące sieć. Podejścia takie będą sprawdzane w kolejnych pracach.

Podsumowanie

W pracy przedstawiono zagadnienie estymacji zmiennych stanu w rzeczywistym układzie dwumasowym z wykorzystaniem konwolucyjnej sieci neuronowej uczoney off-line na próbkach uzyskanych podczas badań symulacyjnych. Sieć wykorzystuje informacje o prędkości silnika oraz momencie elektromagnetycznym przedstawione w postaci dwóch jednowymiarowych wektorów.

Zaprezentowane wyniki potwierdzają, że system działa poprawnie i pozwala skutecznie odtwarzać zarówno

prędkość maszyny roboczej, jak i niedostępny pomiarowo w praktycznym zastosowaniu moment skrotny.

W kolejnych badaniach planowane jest zastosowanie opracowanej struktury w układzie sterowania, dalsze badania nad innymi strukturami sieci oraz rozszerzenie estymowanego wektora stanu o kolejne zmienne i parametry układu. Zasadne wydaje się również porównanie rozwiązań wykorzystujących sieci konwolucyjne z klasycznymi sieciami neuronowymi.

Autorzy: mgr. inż. Piotr Majdański, e-mail: piotr.majdanski@pwr.edu.pl, dr hab. inż. Karol Wróbel, e-mail: karol.wrobel@pwr.edu.pl Politechnika Wrocławska, Katedra Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, dr inż. Rafał Zawislak, e-mail: rafal.zawislak@p.lodz.pl, Politechnika Łódzka, Instytut Automatyki, ul. B. Stefanowskiego 18, 90-537 Łódź

LITERATURA

- [1] Szabat K., Struktury sterowania elektrycznych układów napędowych z połączeniem sprężystym, Oficyna Wydawnicza Politechniki Wrocławskiej, (2008).
- [2] Kamiński M., Tarczewski T., Neural Network Applications in Electrical Drives—Trends in Control, Estimation, Diagnostics, and Construction, *Energies*, 16 (2023), nr 11, 4441
- [3] Gasiyarov V.R., Radionov A.A., Loginov B.M., Zinchenko M. A., Gasiyarova O. A., Karandaev A. S., Khramshin V. R., Method for Defining Parameters of Electromechanical System Model as Part of Digital Twin of Rolling Mill, *Journal of Manufacturing and Materials Processing*, 7 (2023), nr 5, 183
- [4] Kabziński J., Mosiolek P., Integrated, Multi-Approach, Adaptive Control of Two-Mass Drive with Nonlinear Damping and Stiffness, *Energies*, 14 (2021), nr 17, 5475
- [5] Boukhezzar B., Siguerdidjane H., Nonlinear Control of a Variable-Speed Wind Turbine Using a Two-Mass Model, *IEEE Transactions on Energy Conversion*, 26 (2011), nr 1, 149–162
- [6] Malarczyk M., Żychlewicz M., Stanisławski R., Kamiński M., Speed Control Based on State Vector Applied for Electrical Drive with Elastic Connection, *Automation*, 3 (2022), nr 3, 337–363
- [7] Chang X.-H., Huang R., Wang H., Liu L., Robust Design Strategy of Quantized Feedback Control, *IEEE Transactions on Circuits and Systems II: Express Briefs*, 67 (2020), nr 4, 730–734
- [8] Kaczmarczyk G., Stanisławski R., Szrek J., Kamiński M., Adaptive Sliding Mode Control Based on a Radial Neural Model Applied for an Electric Drive with an Elastic Shaft, *Energies*, 17 (2024), nr 4, 833
- [9] Kamiński M., Szabat K., Adaptive Control Structure with Neural Data Processing Applied for Electrical Drive with Elastic Shaft, *Energies*, 14 (2021), nr 12, 3389
- [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*, 25 (2019), nr 16, 2225–2236
- [11] Brock S., Łuczak 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*, 64 (2017), nr 4, 3338–3347
- [12] Żychlewicz M., Stanisławski R., Szrek J., Malarczyk M., Kamiński M., Rozmyty regulator stanu układu dwumasowego, *Przegląd Elektrotechniczny*, 99 (2023), nr 3, 55–60
- [13] Wang C., Yang M., Zheng W., Long J., Xu D., Vibration Suppression With Shaft Torque Limitation Using Explicit MPC-PI Switching Control in Elastic Drive Systems, *IEEE Transactions on Industrial Electronics*, 62 (2015), nr 11, 6855–6867
- [14] Wróbel K., Śleszycki K., Szabat K., Katsura S., Estymacja stanu układu dwumasowego z wykorzystaniem obserwatora wielowarstwowego, *Przegląd Elektrotechniczny*, 99 (2023), nr 5, 184–189
- [15] Kamiński M., Adaptacyjny-neuronowy obserwator Luenbergera zastosowany w estymacji zmiennych stanu układu dwumasowego, *Przegląd Elektrotechniczny*, 90 (2014), nr 6, 79–82
- [16] Serkies P., Szabat K., Zastosowanie obserwatorów z ruchomym oknem MHE do estymacji zmiennych stanu napędu z połączeniem sprężystym, *Przegląd Elektrotechniczny*, 91 (2015), nr 2, 175–178
- [17] Szabat K., Orłowska-Kowalska T., Application of the Kalman Filters to the High-Performance Drive System With Elastic Coupling, *IEEE Transactions on Industrial Electronics*, 59 (2012), nr 11, 4226–4235
- [18] Krzysztofiak M., Tarchała G., Zastosowanie sieci neuronowych do detekcji zwarć zwojowych silnika PMSM z wykorzystaniem modelowania matematycznego, *Przegląd Elektrotechniczny*, 99 (2023), nr 4
- [19] Skowron M., Wolkiewicz M., Orłowska-Kowalska T., Kowalski C. T., Application of Self-Organizing Neural Networks to Electrical Fault Classification in Induction Motors, *Applied Sciences*, 9 (2019), nr 4, 616
- [20] Ince T., Kiranyaz S., Eren L., Askar M., Gabbouj M., Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks, *IEEE Transactions on Industrial Electronics*, 63 (2016), nr 11, 7067–7075
- [21] Kamiński M., Orłowska-Kowalska T., Regulatory neuronowe trenowane off-line zastosowane w strukturze sterowania prędkością napędu dwumasowego, *Przegląd Elektrotechniczny*, 91 (2015), nr 1, 9–12
- [22] Laadjaal K., Amaral A. M. R., Sahraoui M., Cardoso A. J. M., Machine Learning Based Method for Impedance Estimation and Unbalance Supply Voltage Detection in Induction Motors, *Sensors*, 23 (2023), nr 18, 7989
- [23] Gutierrez-Villalobos J. M., Rodriguez-Resendiz J., Rivas-Araiza E.A., Martínez-Hernández M. A., Sensorless FOC Performance Improved with On-Line Speed and Rotor Resistance Estimator Based on an Artificial Neural Network for an Induction Motor Drive, *Sensors*, 15 (2015), nr 7, 15311–15325
- [24] Orłowska-Kowalska T., Szabat K., Neural-Network Application for Mechanical Variables Estimation of a Two-Mass Drive System, *IEEE Transactions on Industrial Electronics*, 54 (2007), nr 3, 1352–1364
- [25] Singstad B.-J., Tronstad C., Convolutional Neural Network and Rule-Based Algorithms for Classifying 12-lead ECGs, (2020) *Computing in Cardiology*, (2020), 1–4
- [26] Skowron, M., Analysis of PMSM Short-Circuit Detection Systems Using Transfer Learning of Deep Convolutional Networks. *Power Electronics and Drives*, 9 (2024), nr 1, 21–33.