

doi:10.15199/48.2023.02.47

Wpływ konfiguracji sieci neuronowej na estymację prędkości kątowej silnika PMSM

Streszczenie. W artykule rozważono wpływ konfiguracji sztucznej sieci neuronowej na estymację prędkości silnika PMSM. Przedstawiono wyniki symulacji komputerowych układu elektromechanicznego zawierającego przekształtnik napięcia, silnik PMSM oraz blok sieci neuronowej. Model symulacyjny został zaprojektowany w programie MATLAB Simulink. W badaniach symulacyjnych uwzględniono trzy różne konfiguracje sztucznej sieci neuronowej.

Abstract. The article considers the influence of the artificial neural network configuration on the PMSM motor speed estimation. The paper presents the results of computer simulations of the electromechanical system including a voltage converter, PMSM motor and a neural network block. The simulation model was designed in MATLAB Simulink. In the simulation studies, three different configurations of the artificial neural network were taken into account. (*Influence of neural network configuration on PMSM motor angular velocity estimation*).

Słowa kluczowe: sztuczne sieci neuronowe, silnik PMSM, sterowanie polowo-zorientowane, estymacja prędkości

Keywords: artificial neural networks (ANN), PMSM motor, field oriented control, velocity estimation

Wstęp

Odtwarzanie prędkości kątowej jest realizowane najczęściej z wykorzystaniem obserwatorów. Na podstawie wielkości elektrycznych mierzonych w modelu symulacyjnym silnika oraz zależności matematycznych obliczana jest prędkość kątowa. Największym problemem większości rozwiązań, w których zastosowano powyższą metodę jest estymacja prędkości kątowej przy małych prędkościach (poniżej dziesięciu procent prędkości znamionowej). Algorytmy bezczujnikowe wykorzystuje się przeważnie w sytuacji, gdy nie jest możliwe zamontowanie przetworników pomiarowych do pomiaru prędkości kątowej z uwagi na ciężkie warunki eksploatacyjne.

Sieci neuronowe są coraz częściej implementowane w algorytmach bezczujnikowych które sterują silnikami elektrycznymi. W układach elektromechanicznych sieć neuronowa najczęściej ma za zadanie odtwarzanie prędkości kątowej silnika. Zastosowanie estymatora neuronowego pozwala na sterowanie silnikiem PMSM (*ang. Permanent Magnet Synchronous Motor*) bez stosowania przetworników do pomiaru prędkości kątowej.

W pracy wykorzystano program MATLAB Simulink do budowy regulatora neuronowego, który powstał przy następujących założeniach:

- wykorzystano sieć jednokierunkową,
- zmieniano ilość warstw ukrytych oraz ilość neuronów w warstwach,
- wszystkie symulacje przeprowadzono z wykorzystaniem takich samych parametrów sieci,
- wszystkie symulacje przeprowadzono z wykorzystaniem tej samej charakterystyki prędkości zadanej,
- uczenie sieci neuronowej przeprowadzono z wykorzystaniem takich samych parametrów konfiguracyjnych,
- moment obciążenia (jeżeli był zadawany) miał tę samą wartość we wszystkich symulacjach.

Opisana analiza sztucznej sieci neuronowej (jednokierunkowej) została przeprowadzona po udanej implementacji do rzeczywistego układu SoC sieci, która odtwarza kąty skręcenia wału w układzie elektromechanicznym. Optymalizacja sieci pod względem ilości warstw oraz ilości neuronów przypisanych każdej warstwie pozwolił zaprojektować rzeczywisty układ z regulatorem neuronowym w sposób optymalny. Wybrano sieć jednokierunkową, gdyż w wystarczającym stopniu

odtwarza parametry obiektu, a jej implementacja programowa nie jest skomplikowana i nie wymaga dedykowanych jednostek obliczeniowych.


Na podstawie licznych badań stwierdzono, iż w metodach algorytmicznych, opierających się na modelach matematycznych obiektów dynamicznych, kluczowym elementem jest dokładna znajomość parametrów obiektu. W przypadku stosowania sztucznych sieci neuronowych parametry w zasadzie nie muszą być znane, gdyż sieć odwzorowuje je w trakcie procesu uczenia [8].

Budowa modelu symulacyjnego

Model symulacyjny został zbudowany przy następujących założeniach:

- czas symulacji ustawiono na 20 sekund, aby zachować czytelność wykresów,
- przekształtnik napięcia nie uwzględniał spadków napięcia na tranzystorach oraz czasu martwego.

Opierając się na powyższych założeniach zbudowano model symulacyjny układu napędowego z silnikiem PMSM, w którym zaimplementowano sztuczną sieć neuronową jednokierunkową (*ang. Feed-Forward Neural Network*), która pełni rolę estymatora prędkości kątowej silnika.



Rys. 1. Model symulacyjny układu napędowego z silnikiem PMSM oraz siecią neuronową

W pracy wykorzystano standardowy algorytm zorientowanego polowo sterowania (*ang. Field Oriented Control, FOC*) silnikiem PMSM w którym sprzężenie zwrotne bloku regulatora prędkości jest połączone z

wyjściem estymatora neuronowego. Sygnałami wejściowymi bloku sieci neuronowej są prądy i napięcia silnika odpowiednio przetworzone oraz wyskalowane.

Model silnika PMSM został zbudowany na podstawie poniższych zależności opisujących część elektryczną oraz mechaniczną silnika [7].

$$(1) \quad u_d = L_d \frac{di_d}{dt} + i_d R - L_q i_q \omega_m p$$

$$(2) \quad u_q = L_q \frac{di_q}{dt} + i_q R + L_d p \omega_m i_d + \lambda p \omega_m$$

$$(3) \quad u_0 = L_0 \frac{di_0}{dt} + i_0 R$$


$$(4) \quad M_e = \frac{3}{2} p [\lambda i_q + (L_d - L_q) i_d i_q]$$

$$(5) \quad J \frac{d\omega_m}{dt} = M_e - M_{obc} - \omega_m B$$


gdzie: i_d, i_q, i_0 - prądy silnika w układzie współrzędnych dq0; u_d, u_q, u_0 - napięcia zasilające w układzie dq0; L_d, L_q, L_0 - indukcyjności uzwojeń w układzie dq0; R - rezystancja uzwojeń; p - liczba par biegunów; ω_m - prędkość kątowna silnika; λ - strumień wzbudzony przez magnesy trwałe wirnika; M_e - moment elektromagnetyczny silnika, M_{obc} - moment obciążenia, B - współczynnik tarcia w łożyskach silnika.

W pracy wykorzystano sieć neuronową, w której zmieniano liczbę neuronów w pierwszej warstwie ukrytej, zmieniono liczbę warstw sieci neuronowej oraz zmieniono funkcję aktywacji w kolejnych seriach pomiarowych. W trzech powyższych przypadkach zastosowano identyczny układ symulacyjno-komputerowy z identycznymi parametrami silnika i algorytmem FOC. Badania estymatora przeprowadzono z wykorzystaniem środowiska MATLAB Simulink.

Każdorazowo po zamianie parametrów sieci przeprowadzano jej uczenie, które polegało na uruchomieniu modelu symulacyjnego, zebraniu danych niezbędnych do procesu uczenia sieci, wywołaniu skryptu do wstępnej konfiguracji sieci oraz wywołaniu polecenia *train*, które na bazie wcześniejszych ustawień przeprowadzało proces uczenia.



Rys. 2. Budowa wewnętrzna bloku sieci neuronowej z dwiema warstwami ukrytymi.



Rys. 3. Budowa wewnętrzna warstwy Layer1.


Proces uczenia sieci w zależności od ilości danych, rozmiaru sieci, ustawionych parametrów oraz możliwości obliczeniowych sprzętu komputerowego trwał od kilku do kilkudziesięciu minut. Program MATLAB umożliwia skrócenie czasu obliczeń numerycznych z wykorzystaniem obliczeń równoległych oraz z wykorzystaniem karty graficznej. W pracy wykorzystano pierwszą metodę, która znacznie skróciła czas uczenia sieci neuronowej.

Badania symulacyjne

Badania przeprowadzono dla trzech różnych konfiguracji sieci neuronowej, które zostały opisane w poniższej tabeli 1. Wyniki symulacji komputerowej (rys. 6, 7 i 8) przedstawiają, odpowiednio, przebiegi prędkości kątowej wirnika silnika PMSM, obliczanej na podstawie równania ruchu (5) i estymowanej przez sieć neuronową oraz różnicę obu prędkości. Schemat przedstawiający sposób obliczania różnicy prędkości pokazano na rys. ku 4.


Tabela 1. Opis konfiguracji sieci

Konfiguracja	Sieć nr 1	Sieć nr 2	Sieć nr 3
Liczba warstw ukrytych	2	3	4
Liczba neuronów na 1. warstwie ukrytej	10	20	40
Liczba neuronów na 2. warstwie ukrytej	5	10	20
Liczba neuronów na 3. warstwie ukrytej	0	5	10
Liczba neuronów na 4. warstwie ukrytej	0	0	5
Funkcja aktywująca	tansig		
Funkcja ucząca	trainbr		

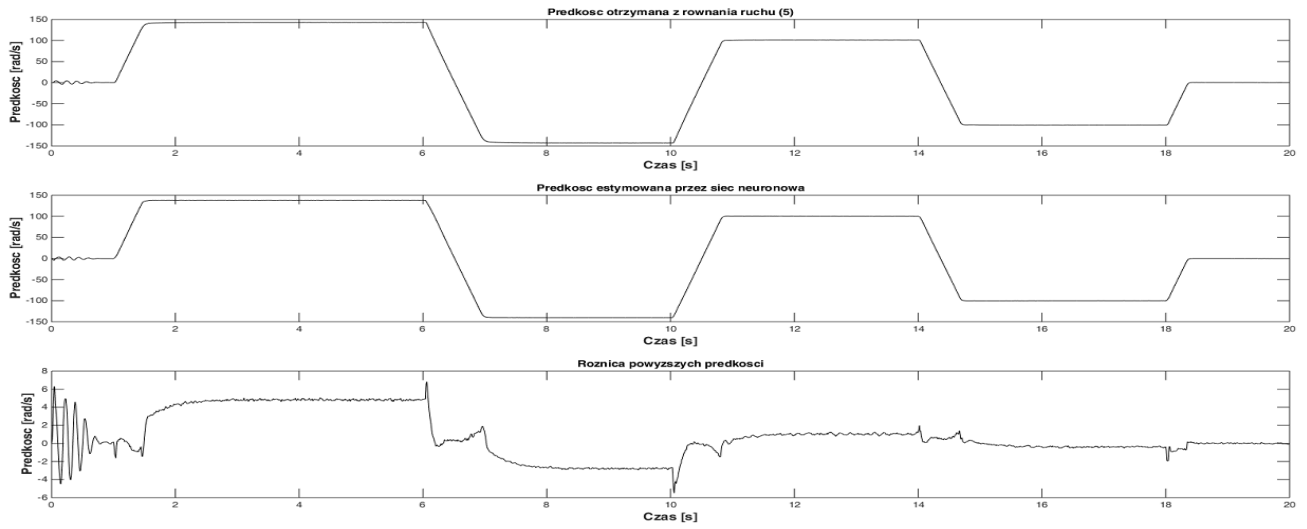


Rys. 4. Schemat przedstawiający sposób obliczania różnicy prędkości otrzymanej z modelu silnika PMSM i prędkości estymowanej przez sieć neuronową


W modelu symulacyjnym charakterystyka prędkości zadanej była identyczna w każdej sytuacji. Czas symulacji komputerowych ustawiono na 20 sekund.




Rys. 5. Prędkość zadana.



Rys. 6. Porównanie prędkości otrzymanej oraz estymowanej dla sieci z dwiema warstwami ukrytymi



Rys. 7. Porównanie prędkości otrzymanej oraz estymowanej dla sieci z trzema warstwami ukrytymi



Rys. 8. Porównanie prędkości otrzymanej oraz estymowanej dla sieci z czterema warstwami ukrytymi

Podsumowanie i wnioski

Z przeprowadzonych badań symulacyjnych wynika, iż sztuczna sieć neuronowa w dobrym stopniu estymuje prędkość kątową silnika PMSM. Powyższy wniosek znajduje poparcie w analizie przebiegów czasowych prędkości kątowej silnika przedstawionych na rysunkach w niniejszej pracy. Na rysunkach od 6 do 8 można zauważyć, iż równica pomiędzy prędkością otrzymaną z modelu symulacyjnego, a prędkością odtworzoną na podstawie prądów i napięć silnika za pomocą sztucznej sieci neuronowej zmniejsza swoją wartość wraz ze zwiększeniem liczby warstw sztucznej sieci neuronowej. Porównując różnicę prędkości z rysunków 7 i 8 można zauważyć, iż wartości są podobne.

Kierując się kompromisem pomiędzy dokładnością odtwarzania prędkości kątowej silnika a stopniem skomplikowania struktury sieci, można stwierdzić na podstawie przeprowadzonej analizy przebiegów, że sieć nr 2 spełnia powyższe oczekiwania w wystarczającym zakresie.

Takie analizy są niezbędne podczas projektowania układów sterowania opartych na sieciach neuronowych. Implementacja algorytmów sztucznej sieci neuronowej, w których występują obciążające procesor numeryczny operacje matematyczne wymaga przeprowadzenia wstępnej optymalizacji. W najprostszej formie optymalizacja polega na doborze ilości warstw oraz liczby neuronów. Kolejnym krokiem może być konwersja liczb zmiennoprzecinkowych na 32-bitowe wartości stałoprzecinkowe, co znacznie skraca czas obliczeń numerycznych, jednakże komplikuje kod programu. Zastosowanie dedykowanych układów SoC (ang. *System on Chip*) wyposażonych w bloki obsługi sieci neuronowych oraz szybkich jednostek obliczeniowych zapewnia właściwą dokładność i dynamikę odpowiedzi sztucznej sieci neuronowej.

Autorzy: mgr inż. Marcjjan Nowak, dr hab. inż. Andrzej Popenda prof. PCz., Politechnika Częstochowska, Wydział Elektryczny, Instytut Elektroenergetyki, Al. Armii Krajowej 17, 42-200 Częstochowa,
E-mail: marcjjan.nowak@pcz.pl, andrzej.popenda@pcz.pl

LITERATURA

- [1] Bose Bimal K. *Modern Power Electronics and AC Drives*, 2002.
- [2] Dubey, S.R.; Chakraborty, S.; Roy, S.K.; Mukherjee, S.; Singh, S.K.; Chaudhuri, B.B. DiffGrad: An Optimization Method for Convolutional Neural Networks. *IEEE Trans. Neural Netw. Learn. Syst.* 2020, 31, 4500–4511
- [3] Glinka T.: *Maszyny elektryczne wzbudzone magnesami trwałymi*, Gliwice 2002.
- [4] Glinka T., Jakubiec M., *Silniki elektryczne z magnesami trwałymi umieszczonymi na wirniku*, *Zeszyty Problemowe – Maszyny Elektryczne*, Nr 71/2005, Komel, Katowice 2005.
- [5] Haddoun A., Benbouzid M., Diallo D., Abdessemed R., Ghouili J., Modeling, Analysis, and Neural Network Control of an EV Electrical Differential. *IEEE Transactions on Industrial Electronics, Institute of Electrical and Electronics Engineers*, 2008, 55 (6), p.2286 - 2294.
- [6] Hagan M. T., Demuth H. B., Beale M. H., De Jesús O., *Neural Network Design*, 2nd Edition, 2014.
- [7] Nowak M.: Analiza drgań giętych wału w układzie napędowym z silnikiem PMSM, *Przegląd elektrotechniczny*, 12/2014.
- [8] Orłowska - Kowalska T.: *Bezczujnikowe układy napędowe z silnikami indukcyjnymi*, *Oficyna Wydawnicza Politechniki Wrocławskiej*, Wrocław 2003.
- [9] Osowski S., *Sieci neuronowe do przetwarzania informacji*, *Oficyna Wydawnicza Politechniki Warszawskiej*, 2006.
- [10] Popenda A.: A Concept of Control of PMSM Angular Velocity, *Przegląd elektrotechniczny*, 12/2013.
- [11] Popenda A., Lis M., Nowak M., Blecharz Krzysztof, Mathematical Modelling of Drive System with an Elastic Coupling Based on Formal Analogy between the Transmission Shaft and the Electric Transmission Line, *Energies*, 2020.
- [12] Rusek A., Shchur I., Mandzyuk M: Power Effective Work of PMSM in Electric Vehicles at the Account of Magnetic Saturation and Iron Losses, *Przegląd elektrotechniczny*, 2015.
- [13] Rusek A., Chaban A., Lis M., A Mathematical Model of a Synchronous Drive with Protrude Poles, an Analysis Using Variational Methods, *Przegląd Elektrotechniczny*, 89 (2013), nr 4, 106-108
- [14] Shao, S.; McAleer, S.; Yan, R.; Baldi, P. Highly Accurate Machine Fault Diagnosis Using Deep Transfer Learning. *IEEE Trans. Ind. Inform.* 2019, 15, 2446–2455
- [15] Shao, S.; Yan, R.; Lu, Y.; Wang, P.; Gao, R. DCNN-based Multi-signal Induction Motor Fault Diagnosis. *IEEE Trans. Instrum. Meas.* 2019, 69, 2658–2669
- [16] Sitao W., Chow T.W.S., Intelligent machine fault detection using SOM based RBF neural networks, *IEEE International Joint Conference on Neural Networks*, 2004, Vol. 3, 2077–2082.