Zastosowanie sztucznej sieci neuronowej do regulacji prędkości kątowej silnika indukcyjnego w układzie sterowania typu IFOC

Mariusz Krupa, Janusz Flasza

1. Wprowadzenie

Elektryczne układy napędowe, składające się głównie z silników elektrycznych, układów zasilających, regulacyjnych oraz obciążających, takich jak np. pompy czy wentylatory, zużywają ok. 40 do 50% energii elektrycznej wyprodukowanej na potrzeby polskiego przemysłu [1, 2]. Jednym ze sposobów na poprawę efektywności energetycznej napędów przemysłowych jest optymalizacja napędów elektrycznych poprzez zastosowanie energooszczędnych silników oraz układów o zmiennej regulacji prędkości obrotowej. Współczesna teoria sterowania napędami elektrycznymi to wynik złożenia kilku dyscyplin nauki i techniki. Obejmuje ona nie tylko klasyczną teorię maszyn elektrycznych, ale teorię napędu elektrycznego, teorię sterowania, elektronikę przemysłową, jak również sztuczną inteligencję. Klasyczne rozwiązania układów sterowania czasami wymagają zaprzęgnięcia rozwiązań alternatywnych, jakimi są sieci neuronowe.

2. Opis modelu symulacyjnego

Przedstawiony w pracy model symulujący sterowanie prędkości kątowej ω_m (rys. 1), stanowi zamknięty układ regulacyjny, opracowany w środowisku programu Matlab/Simulink. W układzie wykorzystano metodę sterowania według orientacji pola, znaną również jako sterowanie typu TRANSVECTOR [3]. Obiekt regulacji stanowi model prądowy trójfazowego silnika asynchronicznego (rys. 2) w układzie współrzędnych (x, y, 0) wirujących synchronicznie z wektorem strumienia wirnika w taki sposób, że $\Psi_R = \Psi_{Rx}$.

W opracowanym modelu występują dwie składowe prądu stojana, tzn. składowa bierna, odpowiedzialna za sterowanie wielkością strumienia wirnika Ψ_R oraz składowa czynna prądu stojana, której rolą jest sterowanie wielkością momentu elektromagnetycznego silnika m_e . Należy przy tym podkreślić, że strumień wirnika Ψ_R = const (w naszym przypadku Ψ_R = 1). W modelu uwzględniono odpowiednie układy przetwarzania sygnałów, w tym również składowych typu x-y prądu stojana na postać zespoloną.

Parametry przyjęte dla symulacji:

- czas symulacji: 60 [s];
- krok symulacji stały: 1e-3;
- algorytm symulacyjny: ode 4 (Runge-Kutta).

Wartości parametrów dla zastosowanego w modelu trójfazowego silnika asynchronicznego:

- 1/TN = 314 [1/s];
- rS = 0,059;
- rR = 0,048;
- xS = xR = 1,92;

Streszczenie: W artykule dokonano porównania wybranych metod sterowania pracą maszyny prądu przemiennego, tj. metody IFOC oraz DTC-SVM, w aspekcie bezczujnikowej regulacji prędkości kątowej silnika indukcyjnego przy wykorzystaniu sztucznych sieci neuronowych. Celem niniejszej pracy jest ocena efektywności działania oraz zasadności stosowania sztucznych sieci neuronowych, przewidzianych do zadań (regulacyjnych) regulacji prędkości kątowej maszyny indukcyjnej w rozwiązaniach praktycznych. Szczególnie interesujące z punktu widzenia procesu regulacji dla przedstawionych metod sterowania są stabilność procesu, odporność na zakłócenia oraz zdolności adaptacyjne rozważanych struktur neuronowych.

Słowa kluczowe: metody sterowania maszyną indukcyjną, sieć neuronowa, regulacja prędkości kątowej

COMPARISON OF METHODS FOR CONTROLLING THE OPERATION OF AC MACHINES IN TERMS OF ANGULAR VELOCITY SENSORLESS CONTROL OF INDUCTION MOTOR USING ARTIFICIAL NEURAL NETWORKS

Abstract: On the basis of the design for a new electric power system including wind-electric and solar power stations, coming into being at the Faculty of Electrical Engineering at Czestochowa University of Technology, the authors intend to present in some stages the possibility of using the existing renewable energy sources to the new opportunities for mini combined heat and power (CHP) plants. The resultant system will be responsible for data collection and analysis to focusing on cogeneration and implementation of the data in true applications.

Keywords: induction machine control method, neural network, the angular speed

- xM = 1,82;
- xMrR/xR = xMrR/xR1 = 0,0455;
- rR/xR = 0,025;
- xM/xR = 0,9479;
- 1/TM = 1,16 [1/s].]

3. Opis zaprojektowanej struktury neuronowej

Zaprojektowaną w modelu symulacyjnym sztuczną sieć neuronową, mającą zadania regulacyjne, stanowi struktura o jednokierunkowym przepływie danych, bez sprzężeń zwrotnych [4]. Wybraną spośród wielu strukturę neuronową otrzymano w wy-



— reklama







niku żmudnego procesu uczenia, przy założeniu właściwych parametrów treningu oraz 326 pełnych cykli iteracji (epok), rys. 3. W procesie uczenia przyjęto algorytm Levenberga-Marquardta (L-M), należący do grupy metod gradientowych, wykorzystujący własności wstecznej propagacji błędu.

Do głównych zalet algorytmu L-M należy wysoka dynamika przeprowadzanego treningu dla wybranej struktury neuronowej oraz znikomy błąd odtwarzania funkcji celu, przedstawionej sieci jako zbiór wartości oczekiwanych na wyjściu.

Opracowana sieć neuronowa posiada 4 neurony w warstwie wejściowej oraz 8 neuronów w I warstwie ukrytej i 2 neurony w II warstwie ukrytej. Na wyjściu sieci obserwowany jest przebieg momentu elektromagnetycznego $m_e = f(t)$, który stanowił w fazie uczenia zbiór wartości oczekiwanych (rys. 4).

Jak widać na rysunku 4, zaprojektowana struktura neuronowa odtwarza oczekiwany przebieg momentu m_e z błędem o znikomej, pomijalnej wartości, nieprzekraczającej 1%. Należy przy tym podkreślić, iż uwzględniony w modelu symulacyjnym regulator typu PI, stanowił na etapie uczenia sieci układ "nauczyciela".

4. Charakterystyki symulacyjne

W rezultacie symulacji przeprowadzonych dla przygotowanego modelu sterowania pracą silnika asynchronicznego otrzymano przebiegi momentu elektromagnetycznego maszyny $m_e = f(t)$. W celu uproszczenia procesu sterowania w zaprezentowanym modelu symulacyjnym pominięto dynamikę układu prze-





Nr 9 • Wrzesień 2013 r. • **135**





Rys. 8. Przebieg prędkości kątowej $\omega_m = f(t)$ dla regulacji neuronowej, przy ω_{mz} = 95 rad/s, t = 60 sec. [opr. wł.]





Rys. 10. Przebieg całkowitego prądu stojana $i_s = f(t)$ dla regulacji neuronowej, przy ω_{mz} = 95 rad/s, t = 60 sec. [opr. wł.]



Rys. 11. Przebieg strumienia wirnika dla maszyny $\Psi_r = f(t)$ dla regulacji typu PI, przy ω_{mz} = 95 rad/s, t = 60 sec. [opr. wł.]



kształtnikowego, z czym związany jest charakter oraz kształt uzyskanych przebiegów przestawionych na rysunkach 5, 6.

Jak wynika z zaprezentowanych przebiegów, opracowana sieć neuronowa dość dobrze poradziła sobie z odwzorowaniem funkcji $m_e = f(t)$, przedstawionej w procesie uczenia. Należy przy tym podkreślić, iż regulator typu PI stanowił dla sieci układ "nauczyciela", który określił funkcję oczekiwaną na wyjściu w fazie treningu. Schodkowy charakter przebiegu momentu elektromagnetycznego, uzyskanego dla regulacji neuronowej, wynika z doboru kroku próbkowania, ustalonego dla modelu symulacyjnego w celu właściwej rejestracji zbiorów danych uczących dla sieci. Dla obydwu przedstawionych wykresów widać brak przeregulowania, który cechuje stabilne układy regulacji. W opracowanym modelu symulacyjnym zasadniczy problem rozważań stanowiła regulacja prędkości kątowej maszyny na wale ω_m . W układzie zrealizowano metodę pośredniej regulacji prędkości, opartą na znanych zależnościach sterowania polowo zorientowanego typu IFOC, z uwzględnieniem modelu prądowego silnika indukcyjnego. W niniejszej pracy dokonano porównania jakości procesu regulacji prędkości kątowej ω_m , przy pomocy konwencjonalnego regulatora typu PI oraz jednokierunkowej struktury neuronowej, bez sprzężeń zwrotnych (typu feedback), zaprojektowanej do tego celu w oparciu o dane uczące. Dla zadanej wartości prędkości kątowej na wale maszyny ω_m otrzymano przebiegi czasowe przedstawione na rys. 7, 8.

Jak widać z powyżej zaprezentowanych przebiegów, sieć neuronowa odwzorowuje zadaną prędkość kątową silnika w sposób łagodny i nieobarczony zauważalnym błędem regulacji, a przy tym zachowuje właściwą dynamikę. Podobnie jak w przypadku regulatora typu PI, brak jest efektu przeregulowania. Należy również zauważyć, że przebieg prędkości dla regulacji PI ma wyraźnie stromy charakter, niespotykany w rzeczywistych układach tego typu. Pod tym względem zaprojektowana struktura neuronowa znacznie lepiej poradziła sobie z zadaniem regulacji prędkości kątowej maszyny. Niemniej jednak należy zauważyć, że w obydwu przypadkach zachodzi znikomy, pomijalnie mały błąd regulacji. Dla rozważanego modelu układu napędowego z silnikiem asynchronicznym oraz przyjętej metody sterowania prędkości kątowej, otrzymano przebiegi prądu stojana i_s zobrazowane na rys. 9, 10.

Przebieg całkowitego prądu stojana i_s silnika indukcyjnego przypomina kształtem przebieg momentu elektromagnetycznego m_e . Wynika to z wyraźnego wpływu składowej prądu stojana i_{sy} , która jest wielkością proporcjonalną do momentu elektromagnetycznego maszyny, zgodnie z przyjętą ideą sterowania polowo zorientowanego. Zadana wartość składowej i_{sx} , proporcjonalnej do strumienia wirnika maszyny Ψ_r , nie wpływa znacząco na obserwowany przebieg, mimo iż całkowity prąd stojana jest sumą obydwu składowych. Początkowy skok wartości prądu stojana dla regulacji typu PI, wynika z fazy rozruchu dla silnika indukcyjnego, uwzględnionego w opracowanym modelu





symulacyjnym. Ponadto należy podkreślić, że zgodnie z metodą sterowania polowo zorientowanego typu IFOC strumień wirnika $\Psi_R = \text{const.}$, a w naszym przypadku $\Psi_R = 1$, co pokazują przebiegi zarejestrowane dla modelu, rys. 11, 12.

Błąd regulacji, wnoszony do układu przez zaprojektowaną sieć neuronową, jest znikomy i podobnie, jak w przypadku regulatora PI nie przekracza 1%, co pokazują zamieszczone przebiegi czasowe na rysunkach 13, 14.

Podsumowanie

Otrzymane w wyniku przeprowadzonych symulacji przebiegi czasowe uwidoczniły wyraźne zalety regulacji neuronowej, do których niewątpliwie należą stabilność procesu, odporność na zakłócenia, wysoka dynamika oraz znikomy, pomijalnie mały uchyb dla regulowanej wielkości. Wszystko to sprawia, że sztuczne sieci neuronowe stanowią niezwykle atrakcyjną i rozwojowa technike sterowania dla różnorodnych obiektów nieliniowych, w tym także dla nowoczesnych układów napędowych z silnikami indukcyjnymi. Ich konkurencyjność w odniesieniu do wielu innych znanych metod regulacji wynika z niewygórowanych wymagań sprzętowych, jak również szerokich możliwości symulacyjnych, rozlicznych zastosowań w modelowaniu, rozwiązywaniu skomplikowanych zagadnień sterowania oraz estymacji wielkości dynamicznych dla silników indukcyjnych. Zrealizowana w układzie regulacja neuronowa ma charakter adaptacyjny, co wynika z przyjętej metody uczenia struktury w fazie treningu. Oznacza to, że sieć ma cechy dynamiczne i potrafi reagować na sygnał zmieniający się w czasie. Ponadto na etapie uczenia wymaga obecności układu "nauczyciela", który nadzoruje proces. W naszym przypadku układ ten stanowił regulator typu PI. Zastosowanie sieci neuronowej w rozważanym modelu symulacyjnym, gwarantuje wysoką jakość procesu

pośredniej regulacji prędkości mechanicznej na wale silnika asynchronicznego, a przy tym eliminuje znane wady regulacji typu PI. Przyjęta struktura neuronowa korzystnie wpłynęła na stabilność rozważanego układu regulacji.

Literatura

- FLASZA J.: Współczesny napęd elektryczny kierunki badań energooszczędności w układach napędowych, Wybrane Zagadnienie Elektrotechniki i Elektroniki WZEE'2003, Częstochowa-Poraj, wrzesień 2003.
- [2] KAŻMIERKOWSKI M.P.: Nowoczesne energooszczędne układy sterowania i regulacji napędów z silnikami indukcyjnymi klatkowymi. Polski Program Efektywnego Wykorzystania Energii w Napędach Elektrycznych. PEMP, Krajowa Agencja Poszanowania Energii SA, Wydanie I, Warszawa 2004.
- [3] KALUS M., SKOCZKOWSKI T.: Sterowanie napędami asynchronicznymi i prądu stałego. WPK JS, 2003.
- [4] Osowski S.: Sieci neuronowe w ujęciu algorytmicznym, WNT, Warszawa 1996.

mgr inż. Mariusz Krupa – Politechnika Częstochowska, Wydział Elektryczny, e-mail: mariusz.krupa84@wp.pl; dr inż. Janusz Flasza – Politechnika Częstochowska, Wydział Elektryczny, e-mail: januszflasza@o2.pl

artykuł recenzowany