

*modele ADALINE, sterowanie wektorowe,
regulacja prędkości, silnik indukcyjny*

Marcin KAMIŃSKI*
Krzysztof P. DYRCZ*

ZASTOSOWANIE MODELI *ADALINE* W STRUKTURZE STEROWANIA PRĘDKOŚCIĄ SILNIKA INDUKCYJNEGO

W niniejszym artykule przedstawiono strukturę sterowania prędkością silnika indukcyjnego, w której wykorzystano regulatory oparte o modele *ADALINE*. Opisane regulatory neuronowe zastosowano w torze regulacji prędkości, strumienia oraz prądów w strukturze bezpośredniego sterowania połowo zorientowanego przy wymuszeniu napięciowym. Zaimplementowane regulatory, oparte na teorii sieci neuronowych, stanowią układy adaptacyjne, które umożliwiają precyzyjne sterowanie, zapewniające dużą dynamikę odpowiedzi układu napędowego. Istotną zaletą proponowanych regulatorów jest uproszczona struktura oraz zredukowana liczba parametrów wyznaczanych w etapie projektowania. W publikacji przedstawione zostały badania symulacyjne prezentujące działanie opisywanej struktury sterowania układu napędowego z silnikiem indukcyjnym.

1. WPROWADZENIE

Napędy elektryczne z silnikami indukcyjnymi stanowią obecnie jedną z najczęściej spotykanych struktur napędowych w praktycznych zastosowaniach. Obserwowana tendencja jest związana przede wszystkim z niskimi kosztami tego typu maszyn, dużą niezawodnością oraz nowoczesniejszymi metodami sterowania ich pracą. Duża liczba aplikacji prowadzi do wzrostu wymagań stawianym układom napędowym z silnikami indukcyjnymi. Wiele aplikacji wymaga precyzji w podążaniu za zadaną trajektorią prędkości lub położenia, przy jednoczesnym zmniejszeniu zakłóceń, odporności struktury sterowania oraz redukcji kosztów realizacji całego projektu.

W związku z powyższym korzystne jest, w celu spełnienia tych wymagań, zastosowanie adaptacyjnych układów sterowania. Należy również zaznaczyć, że w publi-

* Politechnika Wroclawska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, ul Smoluchowskiego 19, 50-372 Wrocław, e-mail: marcin.kaminski@pwr.wroc.pl, krzysztof.dyrcz@pwr.wroc.pl

kacjach spotykanych w specjalistycznej literaturze branżowej lub czasopismach naukowych obserwowany jest istotny wzrost artykułów przedstawiających aplikacje algorytmów związanych ze sztuczną inteligencją w napędzie elektrycznym. Jedną z dominujących dziedzin sztucznej inteligencji, stosowaną w napędzie elektrycznym są sieci neuronowe [1]. Opisywane zastosowania dotyczą najczęściej: sterowania [2], identyfikacji [3], estymacji [4] oraz diagnostyki [5].

Hybrydowym rozwiązaniem spełniającym powyższe założenia jest aplikacja układu regulacji oparta na modelach neuronowych, w których współczynniki wagowe są adaptowane *on-line*. Sztuczne sieci neuronowe stanowią złożoną strukturę, w której elementarne obliczenia można opisać jako skalowanie sygnałów, sumowanie uzyskanych rezultatów, a następnie obliczanie wartości funkcji aktywacji na podstawie otrzymanego argumentu. Należy podkreślić, że liczba tego typu operacji jest najczęściej znacząca, w związku z tym wymagane są duże nakłady obliczeniowe, szczególnie w praktycznych implementacjach. Z tego powodu adaptacja współczynników synaptycznych sieci neuronowej, realizowana *on-line* może być problematyczna. Dlatego też korzystne wydaje się zastosowanie modeli *ADALINE* (*Adaptive Linear Neuron*) [6]. Obecnie spotykanych jest wiele zastosowań takich układów adaptacyjnych, przykładami mogą być: układy sterowania silnikami prądu stałego [7], energoelektronika [8], identyfikacja układów o zmiennych parametrach [9].

Przedstawiony artykuł zawiera pięć rozdziałów, po krótkim wprowadzeniu przedstawiona została ogólna koncepcja struktury sterowania. Następnie opisano neuronowe regulatory adaptacyjne wykorzystujące modele *ADALINE*. W dalszej części pracy zamieszczono wyniki badań, prezentujące pracę układu napędowego. W ostatnim rozdziale zawarto wnioski dotyczące uzyskanych rezultatów oraz wybranej struktury sterowania.

2. STRUKTURA STEROWANIA


Strukturą bazową dla prezentowanych w artykule badań jest układ bezpośredniego sterowania połowo zorientowanego z wymuszeniem napięciowym. Charakterystyczną cechą tego typu strategii sterowania jest uzyskanie, poprzez zastosowanie członu odprzegającego, dwóch niezależnych torów sterowania prądem stojana, odpowiadających za strumień wirnika oraz moment elektromagnetyczny [10]. Spotykane najczęściej w klasycznych rozwiązaniach regulatory *PI* (prędkości, strumienia oraz prądów) zostały zastąpione poprzez regulatory neuronowe *ADALINE*. Testowaną strukturę sterowania przedstawiono na rysunku 1.

Proponowane regulatory przedstawiono szczegółowo w rozdziale 2. W strukturze sterowania przyjęto, w analizowanym przypadku, pełną dostępność pomiarową wszystkich wymaganych zmiennych stanu, w ten sposób pominięto wpływ układów

estymujących na pracę układu. W etapie modelowania nie pominięto układu modulatora wektorowego. Układ falownika napięcia jest często modelowany za pomocą bezpośrednich zależności opisujących napięcia wyjściowe (w układzie $\alpha-\beta$) od napięcia obwodu pośredniczącego (U_d) oraz stanu kluczy (S_A, S_B, S_C) [10]:

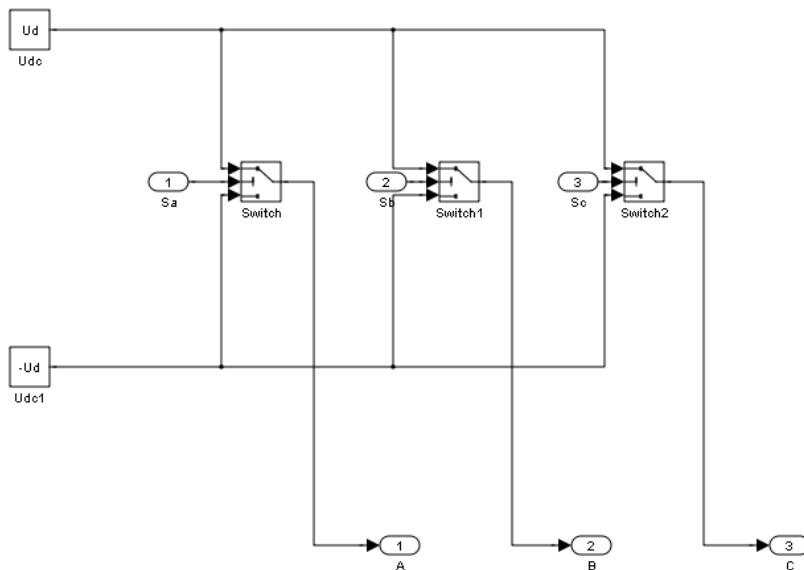
$$U_{s\alpha} = \frac{2}{3}U_d \left(S_A - \frac{1}{2}(S_B + S_C) \right)$$

$$U_{s\beta} = \frac{1}{\sqrt{3}}U_d (S_B - S_C)$$
(1-2)



Rys. 1. Schemat struktury sterowania
Fig. 1. The diagram of the control structure

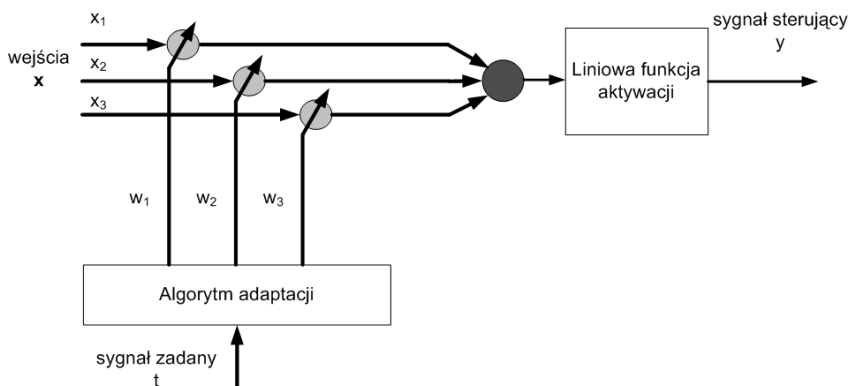
W omawianym przypadku model falownika zrealizowano przy wykorzystaniu struktury przełączającej, dostępnej w programie Simulink. Załączanie kolejnych par kluczy w stosunku do napięcia U_d realizowane jest za pomocą elementów przełączających (Switch1, Switch2, Switch3). Model zastosowanego falownika przestawiono na rysunku 2.



Rys. 2. Model falownika napięcia
Fig. 2. The inverter model

3. NEURONOWE REGULATORY ADAPTACYJNE

Analizowany układ sterowania prędkością silnika indukcyjnego zawiera regulatory wykorzystujące neurony adaptacyjne, których współczynniki adaptowane są w trakcie pracy napędu. Model zastosowanego układu ADALINE przedstawiono na rysunku 3.



Rys. 3. Struktura modelu ADALINE
Fig. 3. The structure of the ADALINE model

W przedstawionym rozwiązaniu zastosowana została liniowa funkcja aktywacji. W każdej iteracji algorytmu następuje adaptacja wartości współczynników wagowych zgodnie z zależnością:

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \Delta\mathbf{w}(k), \quad k = 0, 1, \dots, \quad (3)$$

gdzie \mathbf{w} – macierz wag modelu *ADALINE*.

W celu obliczenia wartości $\Delta\mathbf{w}(k)$ stanowiącej aktualizację wag modelu *ADALINE* przeprowadzana jest analiza, w której zakłada się zależność:

$$E(\mathbf{w}(k+1)) < E(\mathbf{w}(k)). \quad (4)$$

E – różnica pomiędzy sygnałem zadany $t(k)$ a aktualnym $y(k)$.

W przypadku rozwinięcia funkcji błędu w szereg Taylora dla małych wartości $\Delta\mathbf{w}(k)$ uzyskuje się:

$$E(\mathbf{w}(k+1)) = E(\mathbf{w}(k) + \Delta\mathbf{w}(k)) \approx E(\mathbf{w}(k)) + \mathbf{g}(k)\Delta\mathbf{w}(k), \quad (5)$$

gdzie:

$$\mathbf{g}(k) = \frac{\partial \mathbf{E}}{\partial \mathbf{w}}. \quad (6)$$

Warunek (4) jest zachowany jeśli:

$$\mathbf{g}(k)\Delta\mathbf{w}(k) < 0, \quad (7)$$

w związku z tym:

$$\mathbf{w}(k+1) = \mathbf{w}(k) - \alpha\mathbf{g}(k), \quad k = 0, 1, \dots, \quad (8)$$

α – krok obliczeń (mała wartość, dodatnia).

W celu odniesienia przedstawionej analizy do zastosowanego w niniejszym przypadku modelu *ADALINE*, należy przedstawić zależność opisującą sygnał wyjściowy $y(k)$.

$$y(k) = \sum_{i=1}^N x_i(k)w_i(k). \quad (9)$$

W przypadku opisywanej aplikacji zastosowano regułę Delta. Założono wyznaczenie wag zapewniające minimalizację błędu kwadratowego:

$$E(\mathbf{w}(k)) = (y(k) - t(k))^2 = \left(\sum_{i=1}^N x_i(k)w_i(k) - t(k) \right)^2. \quad (10)$$

Gradient powyższej funkcji jest wyrażony następująco:


$$\mathbf{g}(k) = \frac{\partial \mathbf{E}}{\partial \mathbf{w}} = 2 \left(\sum_{i=1}^N x_i(k)w_i(k) - t(k) \right) \mathbf{x}(k). \quad (11)$$

Podstawiając otrzymaną zależność do założenia (8) uzyskiwane jest równanie umożliwiające wyznaczenie wartości wag w kolejnych krokach algorytmu:

$$\mathbf{w}(k+1) = \mathbf{w}(k) - 2\alpha \left(\sum_{i=0}^N x_i(k) w_i(k) - t(k) \right) x_i(k). \quad (12)$$

4. WYNIKI BADAŃ


W niniejszym rozdziale przedstawiono wybrane wyniki badań układu napędowego z regulatorami neuronowymi, opisanymi w poprzedniej części referatu. Rezultaty zamieszczono na rysunkach 4 i 5. Założono krok obliczeń równy $t_s = 0.00001$ s. Testy prezentują odpowiedź napędu na skok wartości zadanej prędkości. Pominięto filtr



Rys. 4. Przebiegi prędkości rzeczywistej oraz zadanej (a),
 hodograf strumienia wirnika (b), składowe prądu stojana (c, d)
 Fig. 4. Transients of the actual and reference speed (a),
 rotor flux hodograph (b),
 components of the stator current (c, d)

wejściowy redukujący szybkość narostu sygnału, w efekcie ograniczający wartość przeregulowania prędkości. Uzyskano krótki czas narostu do wartości zadanej, ustalonej na poziomie 15% wartości znamionowej (rys. 4a).

Przyjęte zostały następujące poziomy współczynniki: $\alpha_{R\omega} = 400$ – w regulatorze prędkości, $\alpha_{R\psi} = 1300$ – w regulatorze strumienia, $\alpha_{ixx} = \alpha_{isy} = 1000$ – w regulatorach prądów. W czasie $t = 0.5$ s załączono moment obciążenia. Wprowadzono ograniczenia prądów w układzie. Widoczne jest skuteczne odprężenie torów sterowania momentem elektromagnetycznym oraz strumieniem wirnika (rys. 4c). W związku z załączeniem momentu obciążenia obserwowany jest wzrost wartości prądu i_{sy} (rys. 4d).



Rys. 5. Wpływ wartości współczynnika α regulatora prędkości na kształtowanie sygnału prędkości (a) oraz sygnału zadanego regulatora (b)

Fig. 5. Influence of the α coefficient in speed controller on speed (a) and output value of the controller (b)

W kolejnych testach zbadano wpływ współczynnika α na działanie układu. Wyniki zaprezentowano na rysunku 5. W tym przypadku pominięto wprowadzane wcześniej ograniczenia sygnałów wyjściowych. Zmiany wprowadzano w regulatorze prędkości, w pozostałych regulatorach wartości tego współczynnika pozostały jak w poprzednim przypadku. Warto zwrócić uwagę na stosunkowo duże wartości współczynnika α , należy zaznaczyć że ta wartość decyduje o szybkości adaptacji zmian wartości wagowych regulatora, a w efekcie dynamice ustalania się sygnałów, nie jest natomiast bezpośrednio związana z wartościami wyjściowymi regulatorów. Wzrost analizowanego współczynnika powoduje szybkie wymuszanie ustalania się wartości sterowanej zmiennej stanu na wymaganym poziomie.

5. PODSUMOWANIE

W artykule zaprezentowano strukturę sterowania prędkością silnika indukcyjnego, w której zastosowano adaptacyjne regulatory neuronowe. Uzyskane wyniki badań

prezentują efektywne sterowanie prędkością układu z bardzo dużą dynamiką podążania prędkości za zmianami sygnału zadanego. Istotnymi zaletami prezentowanych regulatorów są również prostota etapu projektowania, a w efekcie potencjalna prosta implementacja sprzętowa. Kolejne prace w tej tematyce będą dotyczyły praktycznej aplikacji na stanowisku laboratoryjnym.

Praca naukowa finansowana ze środków Narodowego Centrum Nauki w ramach projektu 2011/01/B/ST7/04632.

LITERATURA

- [1] BOSE B.K., *Neural Network Applications in Power Electronics and Motor Drives*, IEEE Trans. Industrial Electronics, 2007, Vol. 54, No. 1, 14–33.
- [2] YONGXIAN SONG, JUANLI MA, HANXIA ZHANG, NAIBAO HE, *Digital implementation of neural network inverse control for induction motor based on DSP*, 2nd International Conference on Future Computer and Communication (ICFCC), 2010, Vol. 1, 174–178.
- [3] KARANAYIL B., RAHMAN M.F., GRANTHAM C., *On-line rotor resistance identification for induction motor drive with artificial neural networks supported by a simple PI stator resistance estimator*, The Fifth Int. Conf. on Power Electronics and Drive Systems, 2003, Vol. 1, 433–438.
- [4] AGUIAR V.P.B., THEPONTES R.S., BRAGA A.P.S., DE AGUIAR S., *A strategy for induction motor stator flux estimation using neural networks*, Int. Conf. on Electrical Machines and Systems ICEMS, 2007, 1923–1927.
- [5] SITAO WU, 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.
- [6] OSOWSKI S., *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2006.
- [7] SHOULING HE, XUPING XU, *Hardware/Software Co-design of an ADALINE Based Adaptive Controller for a DC Motor*, Journal of Computers, 2008, Vol. 3, No. 2, 29–36.
- [8] BOUDJEDAIMI M., WIRA P., OULD ABDESLAM D., DJENNOUNE S., URBAN J.-P., *Voltage source inverter control with Adaline approach for the compensation of harmonic currents in electrical power systems*, 34th Annual Conf. of IEEE Ind. Electronics Soc. IECON, 2008, 2708–2713.
- [9] ZHANG W., *System Identification Based on Generalized ADALINE Neural Network*, International Journal of Intelligent Control and Systems, 2006, Vol. 11, No. 1, 17–25.
- [10] ORŁOWSKA-KOWALSKA T., *Bezczujnikowe układy napędowe z silnikami indukcyjnym*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2003.

IMPLEMENTATION OF ADALINE MODELS IN SPEED CONTROL STRUCTURE OF INDUCTION MOTOR

In this paper speed control structure with ADALINE models for drive with induction motor is presented. Described neural controllers are applied for speed, flux, and currents of direct field oriented control supplied by voltage inverter. Implemented controllers, based on neural networks theory, are adaptive elements provide to precise control with fast response of the system for reference signal. Important advantage of proposed controllers is simplified structure and reduced the number of parameters designated in the design stage. The paper presents results of tests showing correct work of the described speed control structure of induction motor.