

*napęd elektryczny, MRAS, sterowanie wektorowe,
sieć neuronowa, ADALINE, silnik indukcyjny*

Marcin KAMIŃSKI*, Mateusz DYBKOWSKI*

BADANIA EKSPERYMENTALNE ESTYMATORA MRAS^{CC} Z NEURONOWYM MECHANIZMEM WYZNACZANIA PRĘDKOŚCI KĄTOWEJ

W artykule przedstawiono estymator MRAS^{CC}, w którym adaptacja prędkości jest realizowana na podstawie uzyskiwanych sygnałów za pomocą modelu ADALINE (*Adaptive Linear Neuron*). Zaprezentowany został opis matematyczny oraz eksperymentalna weryfikacja założeń teoretycznych dla estymatora testowanego w układzie sterowania wektorowego. Ponadto wykonane zostały badania estymatora dla przypadku niedokładnego oszacowania parametrów elektrycznych i mechanicznych układu napędowego.

1. WPROWADZENIE

Aktualnie, w napędzie elektrycznym dąży się do zastępowania czujników pomiarowych układami odtwarzającymi zmienne stanu. Najpopularniejszą grupę wśród nich stanowią estymatory algorytmiczne, gdzie dominującą rolę odgrywają następujące układy: filtr Kalmana [1], obserwator Luenbergera [2] oraz estymatory wykorzystujące modele odniesienia [3], [4].

W ostatnich latach zakres zastosowań sieci neuronowych w napędzie elektrycznym jest coraz szerszy [5]. Wynika to z korzystnych właściwości takich modeli, dotyczących aproksymacji oraz predykcji danych, równoległego przetwarzania. Jednak jedną z najcenniejszych cech dla zastosowań technicznych jest zdolność do adaptacji, na drodze procesu treningowego, do realizacji określonego zadania, a także generalizacja danych. Praktyczne implementacje związane ze sztuczną inteligencją, które obserwowane są w rosnącej liczbie, wynikają również z gwałtownego rozwoju układów obliczeniowych takich jak procesory sygnałowe oraz matryce FPGA [6]. Sieci neuronowe

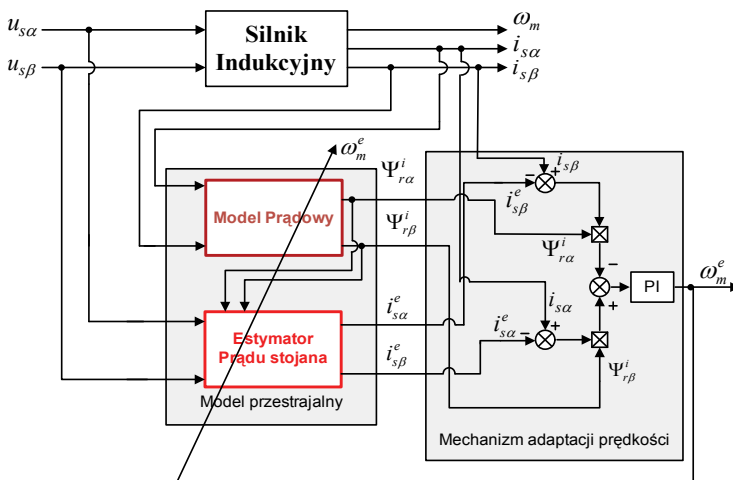
* Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Politechnika Wroclawska, ul Smoluchowskiego 19, 50-372 Wrocław, marcin.kaminski@pwr.wroc.pl, mateusz.dybkowski@pwr.wroc.pl

stanowią równoległą strukturę składającą się najczęściej z licznego zbioru elementarnych obliczeń. Przetwarzanie danych w sieci neuronowej najczęściej wymaga znacznych nakładów obliczeniowych. W związku z tym korzystne wydaje się stosowanie modeli ADALINE, w których liczba operacji jest znacznie zredukowana [7]. Poza tym istotną zaletą modeli neuronowych jest możliwość wyliczania wartości współczynników wagowych on-line, w trakcie pracy całego układu.

W przedstawionym artykule opisano zastosowanie modelu ADALINE w układzie wyznaczania prędkości kątowej estymatora prędkości i strumienia wirnika MRAS^{CC}. Celem przeprowadzonych testów była weryfikacja eksperymentalna rezultatów uzyskanych we wcześniejszych pracach Autorów [8]. Opracowany wcześniej algorytm został zaimplementowany w języku C na karcie dSPACE1104, a następnie uruchomiony na stanowisku laboratoryjnym. W niniejszej pracy zaprezentowano model matematyczny analizowanego estymatora, następnie przedstawiono szczegóły dotyczące układu wyznaczania prędkości kątowej, w dalszej części opisano szczegółowo sposób wykonania badań na obiekcie rzeczywistym oraz uzyskane rezultaty.

2. MODEL MATEMATYCZNY ESTYMATORA MRAS^{CC}

Model matematyczny estymatora MRAS^{CC} opiera się na powszechnie znanych symulatorach zmiennych stanu, na modelu napięciowym i modelu prądowym strumienia wirnika. Szczegółowy opis, badania stabilności i wrażliwości przedstawiono w [3]. Schemat analizowanego układu zaprezentowano na rys. 1.



Rys. 1. Schemat blokowy estymatora MRAS
Fig. 1. Scheme of the MRAS^{CC} estimator

Do wyznaczania strumienia wirnika wykorzystany jest model prądowy strumienia opisany zależnością:

$$\begin{aligned}\psi_{r\alpha} &= \frac{1}{T_n} \int \left(\frac{r_r x_m}{x_r} i_{s\alpha} - \frac{r_r}{x_r} \psi_{r\alpha} - \omega_{est} \psi_{r\beta} \right) dt \\ \psi_{r\beta} &= \frac{1}{T_n} \int \left(\frac{r_r x_m}{x_r} i_{s\beta} - \frac{r_r}{x_r} \psi_{r\beta} + \omega_{est} \psi_{r\alpha} \right) dt\end{aligned}\quad (1)$$

Estymator prądu opisany jest układem równań:

$$\begin{aligned}i_{s\alpha est} &= \int (-i_{s\alpha} c_1) + u_{s\alpha} c_2 + c_3 \psi_{r\alpha} + (\psi_{r\beta} \omega_m c_4) dt \\ i_{s\beta est} &= \int (-i_{s\beta} c_1) + u_{s\beta} c_2 + c_3 \psi_{r\beta} - (\psi_{r\alpha} \omega_m c_4) dt\end{aligned}\quad (2)$$

gdzie:

$$\begin{aligned}c_1 &= \frac{(r_r x_m^2) + (r_s x_r^2)}{T_n (x_s x_r^2) \left(1 - \frac{x_m^2}{x_r x_s} \right)}, & c_2 &= \frac{r_r x_m}{T_n x_s \left(1 - \frac{x_m^2}{x_r x_s} \right)}, \\ c_3 &= \frac{r_r x_m}{T_n x_r^2 x_s \left(1 - \frac{x_m^2}{x_r x_s} \right)}, & c_4 &= \frac{x_m}{T_n x_r x_s \left(1 - \frac{x_m^2}{x_r x_s} \right)}\end{aligned}$$

Uzyskane wartości zmiennych stanu wykorzystywane są w wyjściowym bloku wyznaczającym wartość estymowaną prędkości. W klasycznym przypadku implementowany jest w tym celu regulator PI, wówczas obliczenia tego etapu przetwarzania danych w estymatorze mogą być wyrażone wzorem:

$$\omega_{est} = K_p (e_{i_{s\alpha}} \psi_{r\beta}^i - e_{i_{s\beta}} \psi_{r\alpha}^i) + K_i \int (e_{i_{s\alpha}} \psi_{r\beta}^i - e_{i_{s\beta}} \psi_{r\alpha}^i) dt \quad (3)$$

W artykule regulator PI zastąpiono modelem ADALINE. Badania wykonano w polowo zorientowanej strukturze sterowania [10].

3. MODEL ADALINE

Model ADALINE stanowi nieskomplikowaną strukturę adaptacyjną której współczynniki mogą być przestrajane w trakcie zmian sygnałów wejściowych. Skalowane sygnały wejściowe są sumowane, po czym wprowadzane jako argument funkcji aktywacji [7], [11]. W opisywanym zastosowaniu przyjęto liniową funkcję aktywacji. Po-


nadto pominięte zostało wejście „biasu”. Schemat modelu ADALINE został zamieszczony na rys 2.

Sygnal wyjściowy analizowanego neuronu opisany jest poniższym równaniem:

$$y(k) = f(u(k)), \quad (4)$$

$$u(k) = \sum_{i=1}^N x_i(k)w_i(k), \quad (5)$$

gdzie: f – przykładowa funkcja aktywacji, w_i – współczynniki wagowe, x_i - sygnały wejściowe, u – argument funkcji aktywacji, b – wartość „biasu”.



Rys. 2. Struktura modelu ADALINE
Fig. 2. Scheme of the ADALINE model

Aktualizacja macierzy współczynników wagowych \mathbf{w} w modelu ADALINE przeprowadzana jest iteracyjnie zgodnie ze wzorem:

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \Delta\mathbf{w}(k), \quad k = 0, 1, \dots \quad (6)$$

Zmiana wag o wartość $\Delta\mathbf{w}(k)$, powinna umożliwiać minimalizację błędu E , zatem obliczenia w kolejnych krokach algorytmu adaptacji prowadzą do zrealizowania warunku:

$$E(\mathbf{w}(k+1)) < E(\mathbf{w}(k)). \quad (7)$$

Rozwijając funkcję błędu w szereg Taylora dla małych wartości $\Delta\mathbf{w}(k)$ uzyskuje się:

$$E(\mathbf{w}(k+1)) = E(\mathbf{w}(k) + \Delta\mathbf{w}(k)) \approx E(\mathbf{w}(k)) + \mathbf{g}(k)\Delta\mathbf{w}(k), \quad (8)$$

gdzie \mathbf{g} jest macierzą gradientu funkcji celu względem wartości wag:

$$\mathbf{g}(k) = \frac{\partial \mathbf{E}}{\partial \mathbf{w}}. \quad (9)$$

Warunek opisany zależnością (7) jest spełniony, jeśli:

$$\mathbf{g}(k)\Delta\mathbf{w}(k) < 0 \quad (10)$$

czyli:

$$\mathbf{w}(k+1) = \mathbf{w}(k) - \alpha\mathbf{g}(k), \quad k = 0, 1, \dots \quad (11)$$

α – krok obliczeń.

W analizowanym przypadku funkcję celu E definiuje się jako:

$$E(\mathbf{w}(k)) = (y(k) - d(k))^2 = \left(\sum_{i=1}^N x_i(k)w_i(k) - d(k) \right)^2. \quad (12)$$

Dla tak zdefiniowanego błędu macierz gradientu przyjmuje postać:

$$\mathbf{g}(k) = \frac{\partial E}{\partial \mathbf{w}} = 2 \left(\sum_{i=0}^N x_i(k)w_i(k) - d(k) \right) \mathbf{x}_i(k). \quad (13)$$

Podstawiając otrzymaną zależność do równania (11) otrzymywana jest zależność opisująca adaptację wag w modelu:

$$\mathbf{w}(k+1) = \mathbf{w}(k) - 2\alpha \left(\sum_{i=0}^N x_i(k)w_i(k) - d(k) \right) \mathbf{x}_i(k). \quad (14)$$

W opisywanym przypadku zastosowania neuronu ADALINE, w algorytmie adaptacji estymatora MRAS^{CC}, przetwarzany wektor wejściowy neuronu zawiera następujące zmienne stanu:

$$\mathbf{x} = \left[e_{is\alpha} \Psi_{r\beta}^i; e_{is\beta} \Psi_{r\alpha}^i \right]^T, \quad (15)$$

natomiast wartość błędu determinującego zmiany nastaw modelu ADALINE zdefiniowano następująco:

$$\mathbf{e} = \left(e_{is\alpha} \Psi_{r\beta}^i - e_{is\beta} \Psi_{r\alpha}^i \right). \quad (16)$$

Wartość współczynnika α została wyznaczona w niniejszej aplikacji doświadczalnie.


4. BADANIA EKSPERYMENTALNE

W niniejszym rozdziale zaprezentowano wybrane wyniki badań eksperymentalnych układu napędowego sterowanego metodą DFOC z estymatorem MRAS z neuronowym mechanizmem wyznaczania prędkości kątowej.

Uzyskiwane wyniki estymacji, prędkości oraz strumienia wirnika, realizowanej za pomocą układu MRAS^{CC} oraz neuronu ADALINE oceniono za pomocą błędu zdefiniowanego następującym wzorem:

$$Err = \frac{\sum_{i=1}^p |x_i - \hat{x}_i|}{p} \cdot 100, \quad (17)$$

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



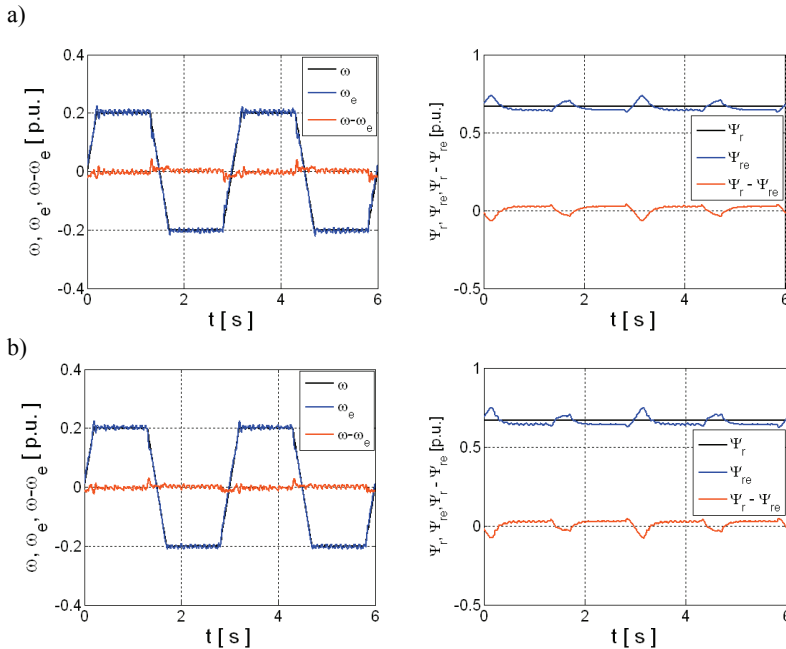
Rys. 3. Przebiegi rzeczywiste i estymowane oraz chwilowe różnice dla: prędkości (a, c, e) i strumienia wirnika (b, d, f) dla następujących wartości parametru układu adaptacji: $\alpha = 0.01$ (a, b), $\alpha = 1$ (c, d), $\alpha = 100$ (e, f)

Fig. 3. Measured and estimated transients and reconstruction error of speed (a, c, e) and rotor flux (b, d, f) for $\alpha = 0.01$ (a, b), $\alpha = 1$ (c, d), $\alpha = 100$ (e, f)

W pierwszym etapie badań testowano wpływ wartości parametru α w członie wyznaczania prędkości estymatora MRAS (rys. 3, tab. 1). Prezentowane testy wykonano dla cyklicznych nawrotów napędu realizowanych pomiędzy stanami ustalonymi prędkości na poziomie 20% wartości znamionowej. Przebadano szeroki zakres zmian tego współczynnika. Badania przedstawiają wpływ wprowadzanych wartości na szybkość dostrajania wartości elementu adaptacyjnego estymatora. Jeżeli poziom współczynnika α jest relatywnie niewielki czas uzyskiwania poprawnej estymaty jest wydłużony, zwiększanie – powoduje przyspieszenie adaptacji. Wzrost przyjmowanych wartości powyżej jedynki nie wpływa znacząco na pracę estymatora, zwiększa nieznacznie poziom zakłóceń uzyskiwanych przebiegów. Zatem, wszystkie pozostałe, prezentowane w opracowaniu badania, zostały zrealizowane dla $\alpha = 1$.


Tabela 1. Błędy odtwarzania zmiennych stanu
Table 1. Errors of state variables estimation

α	$\Delta\omega$	$\Delta\Psi$
0.01	4.81	21.08
0.1	0.90	4.48
1	0.67	2.72
10	0.67	2.65
100	0.76	2.67




Rys. 4. Wpływ zmian rezystancji wirnika na pracę estymatora MRAS; 80% r_r (a), 120% r_r (b)
Fig. 4. Influence of the rotor resistance variations on the MRAS type estimator; 80% r_r (a), 120% r_r (b)

W kolejnych testach sprawdzano wpływ niedokładności oszacowania parametrów silnika na dokładność estymacji. Uzyskane wyniki zamieszczono na rys. 4–6. Zestawienie błędów odtwarzania zmiennych stanu zamieszczono w tabeli 2. Zmiany rezystancji wpływają nieznacznie na dokładność estymacji. Największe zakłócenia pojawiają się przy zmianach reaktancji magnesującej. Znacznie większą precyzją charakteryzują się estymaty prędkości, w porównaniu z wynikami dla strumienia wirnika.



Rys. 5. Wpływ zmian reaktancji magnesującej na pracę estymatora MRAS; 80% x_m
 Fig. 5. Influence of the magnetizing reactance variations on the MRAS type estimator; 80% x_m



Rys. 6. Wpływ zmian rezystancji stojana na pracę estymatora MRAS; 80% r_s (a), 120% r_s (b)
 Fig. 6. Influence of the stator resistance variations on the MRAS type estimator; 80% r_s (a), 120% r_s (b)

Tabela 2. Błędy odtwarzania zmiennych stanu
Table 2. Errors of state variables estimation

Zmiany parametrów	$\Delta\omega$	$\Delta\Psi$
$0,8 \cdot r_r$	0,75	2,32
$120 \cdot r_r$	0,56	2,53
$0,8 \cdot r_s$	0,71	3,24
$120 \cdot r_s$	0,65	2,43
$0,8 \cdot x_m$	1,35	17,37

4. PODSUMOWANIE

W artykule opisano zagadnienia teoretyczne dotyczące modelu MRAS^{CC} z zastosowanym neuronem ADALINE jako układem obliczającym prędkość w strukturze estymatora. Dla zaprezentowanej struktury układu odtwarzającego przeprowadzono badania eksperymentalne na stanowisku laboratoryjnym. Uzyskane wyniki prezentują znaczącą precyzję estymacji. Zmiany parametru α kształtują dynamikę układu. Odpowiedni jego dobór wpływa na dokładność uzyskiwanych wyników dla obu zmiennych stanu. Ponadto testowano odporność estymatora na zmiany parametrów silnika. Otrzymane wyniki prezentują niewielki wpływ wprowadzanych zakłóceń dla większości przypadków, największe niedokładności estymat otrzymano dla zmian reaktancji magnesującej.

LITERATURA

- [1] KRZYSZTOF D., ORŁOWSKA-KOWALSKA T., *Induction motor speed and flux estimation using extended Kalman filter algorithm*, Archives of Electrical Engineering, 2003, Vol. LII, No. 3, 269–290.
- [2] ORŁOWSKA-KOWALSKA T., *Application of extended Luenberger observer for flux and rotor time-constant estimation in induction motor drives*, IEE Proceedings D Control Theory and Applications, 1989, Vol. 136, No. 6, 324–330.
- [3] ORŁOWSKA-KOWALSKA T., DYBKOWSKI M., *Stator-Current-Based MRAS Estimator for a Wide Range Speed-Sensorless Induction-Motor Drive*, IEEE Transactions on Industrial Electronics, 2010, Vol. 57, No. 4, 1296–1308.
- [4] DYBKOWSKI M., ORŁOWSKA-KOWALSKA T., *Analiza dynamiki prądowego estymatora MRAS strumienia i prędkości wirnika silnika indukcyjnego*, Przegląd Elektrotechniczny, 2008, nr 6, 165–168.
- [5] BOSE B.K., *Neural Network Applications in Power Electronics and Motor Drives*, IEEE Transactions on Industrial Electronics, 2007, Vol. 54, No. 1, 14–33.
- [6] MOMMASON E., IDKHAJINE L., CIRSTEA M.N., BAHRI I., TISAN A., NAOUAR M.W., *FPGAs in Industrial Control Applications*, IEEE Trans. Industrial Electronics, May 2011, Vol. 7, No. 2, 224–243.

- [7] FAUSETT L.V., *Fundamentals of Neural Networks: Architectures, Algorithms And Applications*, Prentice Hall, 1993.
- [8] KAMIŃSKI M., DYBKOWSKI M., *Analiza układu bezczujnikowego wektorowego sterowania silnikiem indukcyjnym z estymatorem MRASCC z neuronowym mechanizmem wyznaczenia prędkości kątowej*, Mat. konf. SENE, 2011.
- [9] ORŁOWSKA-KOWALSKA T., DYBKOWSKI M., *Zastosowanie estymatorów typu MRAS do odtworzenia strumienia i prędkości wirnika oraz parametrów uzwojenia stojana w bezczujnikowym napędzie indukcyjnym*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej nr 62, ser. Studia i Materiały, nr 28, 2008, 362–372.
- [10] ORŁOWSKA-KOWALSKA T., *Bezczujnikowe układy napędowe z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2003.
- [11] WIDROW B., LEHR M.A., *Perceptrons, Adalines, and Backpropagation, Handbook of Brain Theory and Neural Networks*, MIT Press, 1995, 719–724.

EXPERIMENTAL TESTS OF THE MRAS^{CC} ESTIMATOR WITH NEURAL SPEED ADAPTATION MECHANISM

In this paper MRAS^{CC} (Model Reference Adaptive System) model applied for estimation of rotor flux and angular speed of induction machine is presented. The main part of analysed system consist of current model and rotor circuit simulator. Adaptation of speed value is realised based on obtained signals using ADALINE (*Adaptive Linear Neuron*). In article mathematical description and experimental verification of theoretical considerations is presented. Estimator is tested in field oriented control structure. Moreover, researches of analysed model, in case of inaccurate information about electrical and mechanical parameters of the drive, are presented.