

*estymacja zmiennych stanu, napęd PMSM,
sztuczne sieci neuronowe*

Krzysztof DRÓŻDŻ*, Marcin KAMIŃSKI*,
Piotr J. SERKIES*, Krzysztof SZABAT*

**ZASTOSOWANIE SIECI NEURONOWYCH
DO ESTYMACJI PRĘDKOŚCI NAPĘDU ELEKTRYCZNEGO
Z SILNIKIEM SYNCHRONICZNYM
Z MAGNESAMI TRWAŁYMI**

W niniejszym artykule zaprezentowano analizę możliwości zastosowania sieci neuronowych w estymacji prędkości silnika synchronicznego z magnesami trwałymi. W celu realizacji tego zadania zastosowano jednokierunkowe wielowarstwowe sieci neuronowe (*Multi Layer Perceptron Neural Network*). Opisana została metodyka projektowania, ze szczególnym uwzględnieniem doboru struktury sieci neuronowej oraz postaci wektora wejściowego. Przedstawiono wybrane wyniki badań zaprojektowanego modelu neuronowego. Uzyskano bardzo wysoką dokładność odtwarzania prędkości silnika. Badania potwierdziły też odporność estymatora na zmiany rezystancji stojana maszyny. Obliczenia związane z opracowanym modelem wykonano w środowisku Matlab.

1. WPROWADZENIE

Estymacja zmiennych stanu układów napędowych jest jednym z głównych trendów rozwoju napędów elektrycznych. Zagadnienia związane z odtwarzaniem zmiennych stanu w rozpatrywanym obszarze można podzielić na dwie główne grupy [5]:

- metody algorytmiczne,
- oraz zastosowanie modelowania neuronowego.

Wśród metod algorytmicznych należy wymienić symulatory zmiennych stanu, obserwatory zmiennych stanu oraz metody bazujące na teorii filtra Kalmana [2]. W przypadku zastosowania symulatorów zmiennych stanu odtwarzana zmienna jest wyznaczana z odpowiedniego równania różniczkowego, z wykorzystaniem dostęp-

* Instytut Maszyn Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, ul. Smoluchowskiego 19, 50-372 Wrocław, e-mail: krzysztof.drozdz@pwr.wroc.pl; marcin.kaminski@pwr.wroc.pl; piotr.serkies@pwr.wroc.pl; krzysztof.szabat@pwr.wroc.pl

nych pomiarowo i łatwo mierzalnych sygnałów struktury sterowania (np. prąd) [1], [4]. W innym przypadku realizowane są modele odpowiednich układów według znanego z teorii sterowania algorytmów estymacji zmiennych stanu obiektów dynamicznych [8]. Analizując wymienione powyżej metody postępowania w estymacji zmiennych stanu należy zaznaczyć, że dokładność uzyskiwanych wyników w każdym z przypadków zależy od precyzji posiadanych informacji dotyczących parametrów układu napędowego oraz jego opisu matematycznego.

Odmiana sytuacja jest w przypadku zastosowania sieci neuronowych. Etap identyfikacji zostaje praktycznie pominięty, a precyzyjną, zrealizowaną w etapie treningu sieci neuronowej. Tego typu modele zawierają dużą liczbę współczynników, które są dobierane za pomocą algorytmu optymalizacyjnego, który minimalizuje funkcję celu. Ten proces projektowania może zostać zrealizowany *off-line* na podstawie uprzednio przygotowanego zbioru danych treningowych [6] lub *on-line* [3], przy zastosowaniu modelu odniesienia. Właściwości sieci neuronowych oraz aktualne możliwości praktycznej implementacji sprzętowej powodują, że liczba aplikacji związanych z tego typu układami zastosowanymi w napędzie elektrycznym rośnie [1].

Od współczesnych układów napędowych oczekuje się bardzo dobrej dynamiki i minimalizacji wymiarów silnika napędowego. Wymagania te spełniają silniki synchroniczne o magnesach trwałych, które przy małej masie i niskim momencie bezwładności mają dużą przeciążalność momentem. [9]. W związku z powyższymi zaletami silniki te praktycznie wyparły inne konstrukcje w zastosowaniach, w których wymagana jest wysoka dynamika napędu.

W artykule przedstawiono zagadnienia projektowania neuronowych estymatorów dla silników PMSM.

2. MODEL MATEMATYCZNY NAPĘDU

Model silnika w jednostkach względnych dla układu współrzędnych związanych z wirnikiem ($d-q$) składa się z następujących równań [9]:

$$u_d = R_s i_d + T_N \frac{d\psi_d}{dt} - \omega L_q i_q, \quad (1)$$

$$u_q = R_s i_q + T_N \frac{d\psi_q}{dt} + \omega L_d i_d, \quad (2)$$

$$\frac{d\omega}{dt} = \frac{1}{T_M} ((\psi_d i_q - \psi_q i_d) - m_L), \quad (3)$$

$$\frac{d\Theta}{dt} = \omega \quad (4)$$

gdzie:

u_d, u_q, i_d, i_q – napięcia i prądy stojana w osiach d i q ,

R_s – rezystancja stojana,

L_d, L_q – indukcyjności w osiach d i q ,

Ψ_d, Ψ_q – strumienie w osiach d i q ,

Ψ_f – strumień od magnesów trwałych,

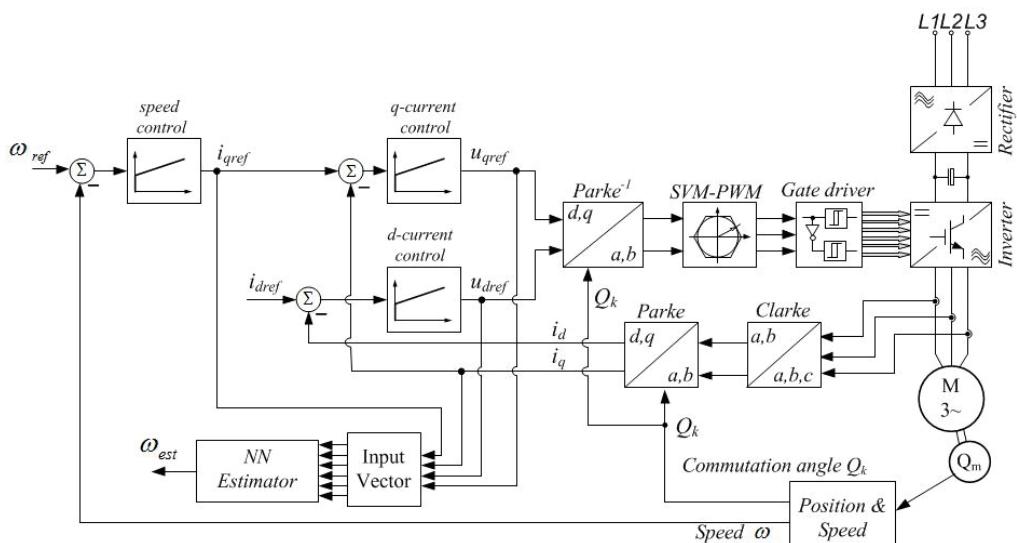
ω – prędkość kątowa wirnika,

m_L – moment obciążenia,

T_m – mechaniczna stała czasowa,

T_N – wielkość podstawowa czasu.

W przypadku silników synchronicznych o magnesach trwałych do sterowania momentem można zastosować polowo zorientowaną strukturę sterowania. W tym przypadku we współrzędnych d - q związanych z wirnikiem. Strukturę sterowania przedstawiono na rysunku 1.

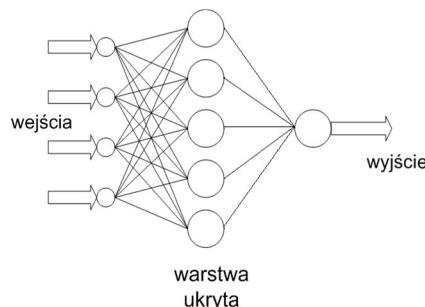


Rys. 1. Struktura sterowania

W osi d w przypadku pracy bez osłabiania pola, prąd powinien być utrzymywany na wartości 0. Wartość momentu elektromagnetycznego w przypadku liniowego modelu silnika jest wprost proporcjonalna do wartości prądu w osi q i zależy od parametrów konstrukcyjnych maszyny. Pomiar położenia kątowego wirnika realizowany jest przeważnie za pomocą rezolwera. Wartość prędkości obliczano jako pochodną położenia.

3. ESTYMATORY NEURONOWE

Modele neuronów realizują sumowanie sygnałów wejściowych skalowanych poprzez współczynniki wagowe, uzyskany wynik stanowi argument dla zastosowanej funkcji aktywacji. Takie elementy odpowiednio połączone stanowią strukturę sieci neuronowej. W analizowanym przypadku zastosowano model o jednej warstwie ukrytej. Wprowadzanie kolejnych warstw ukrytych znaczaco komplikuje złożoność numeryczną estymatora neuronowego. W trakcie przetwarzania danych poprzez sieć neuronową, w analizowanym przypadku, nie występują wewnętrzne sprzężenia zwrotne. Warstwy: wejściowa, ukryta oraz wyjściowa są relatywnie do kierunku przesyłania sygnałów umieszczone szeregowo, natomiast nie występują połączenia pomiędzy neuronami danej warstwy. Schemat przykładowej struktury sieci neuronowej przedstawiono na rysunku 2.



Rys. 2. Przykładowa struktura sieci neuronowej

Sygnal wyjściowy poszczególnych neuronów opisany jest poniższą zależnością:

$$y_j = f \left(\sum_{k=1}^N w_{jk} x_k(t) + w_{j0} \right), \quad (5)$$

$$f(u) = \operatorname{tgh}(\beta u) \quad (6)$$

gdzie:

f – funkcja aktywacji,

w_{jk} – współczynnik wagowy,

x_k – sygnał wejściowy neuronu,

β – współczynnik skalujący funkcji aktywacji,

u – argument funkcji aktywacji,

w_{j0} – wartość biasu (dobierana w trakcie obliczeń algorytmu uczenia).

W zastosowanej sieci neuronowej wykorzystano powyżej opisane funkcje aktywacji warstwy ukrytej, w neuronie wyjściowym obliczenia realizowano zgodnie z funkcją liniową. Ponadto wprowadzono współczynnik biasu dla każdego z neuronów.

Liczba neuronów w warstwach: wejściowej oraz wyjściowej zależy od rozmiaru przetwarzanych danych. Problematiczny jest dobór liczby neuronów w warstwie ukrytej. Należy zaznaczyć, że jest to jeden z najistotniejszych czynników wpływających na właściwości generalizacyjne modelu neuronowego. Możliwe jest wyodrębnienie trzech głównych technik postępowania w celu optymalizacji właściwości generalizacyjnych sieci neuronowych [7]:

- oddziaływanie na długość procesu uczenia,
- wprowadzenie regularyzacji,
- modyfikacja struktury sieci neuronowej.

Wartości współczynników połączeń wagowych wyznaczano *off-line*, na podstawie uprzednio przygotowanego zbioru danych, za pomocą algorytmu Levenberga–Marquardta [7]. W każdej iteracji procesu treningu następuje adaptacja wag zgodnie z zależnością:

$$\Delta \mathbf{w} = -(\mathbf{J}^T \mathbf{J} + \gamma \mathbf{I})^{-1} \mathbf{J}^T \mathbf{e} \quad (7)$$

gdzie:

- \mathbf{J} – jakobian funkcji celu względem poszczególnych wag,
- γ – współczynnik uczenia,
- \mathbf{I} – macierz jednostkowa,
- \mathbf{e} – różnica między wyjściem sieci, a wartością zadaną.

W analizowanym przypadku wartości wyjściową sieci neuronowej była prędkość silnika, testowano różne postacie wektora wejściowego (rysunek 4). Wybór wejściowych zmiennych stanu był determinowany dostępnością pomiarową wybranych sygnałów: napięć zadanych w osiach d i q , prądu zadanego w osi q oraz prądu w osi q .

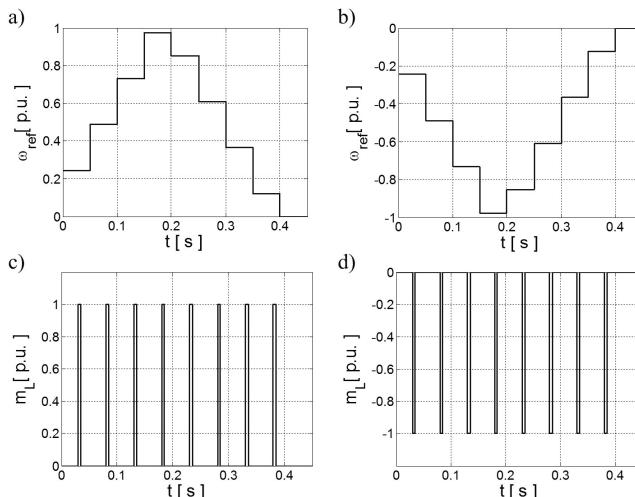
4. UZYSKANE WYNIKI

Badaniom poddano opisane powyżej estymatory neuronowe testowane w strukturze sterowania przedstawionej na rysunku 2. Dane zamodelowanego układu przedstawiono w tabeli 1. W celu uzyskania danych dla estymatora neuronowego w układzie załączono zadane trajektorie prędkości oraz momentu obciążenia, przedstawione na rysunku 3. Przebiegi podzielono na dwie części, aby zredukować liczbę próbek w poszczególnych testach.

Analizie poddano dwa układy kształtujące wektory wejściowe sieci neuronowych, które przedstawiono na rysunku 4. W pierwszym, widocznym na rysunku 4a), wykorzystano informację o prądzie w osi q i napięciu zadanym w tej osi. W drugim przypadku, widocznym na rysunku 4b), dodano informację o zadanym prądzie w osi q i zadanym napięciu w osi d . Ponadto, w celu uzyskania lepszych właściwości w stanach dynamicznych zaimplementowano człony inercyjne pierwszego rzędu oraz różniczkujące z filtracją sygnałów wprowadzanych do sieci neuronowej.

Tabela 1. Dane zamodelowanego układu

Parametr		Wartość	Jednostka
Moment znamionowy	M_N	1,09	Nm
Moment maksymalny	M_{\max}	3,3	Nm
Prędkość znamionowa	n_N	7800	obr/min
Prąd znamionowy	I_N	2,2	A
Moc znamionowa	P_N	893	W
Stała momentu	k_T	0,501	Nm/A
Stała elektromagnetyczna	k_e	0,435	V/rad/s
Rezystancja stojana	R_s	3,35	Ω
Indukcyjność w osi d	L_d	7,202	mH
Indukcyjność w osi q	L_q	7,233	mH
Moment bezwładności	J	0,0001	kgm^2



Rys. 3. Zadane trajektorie: prędkości (a, b) oraz momentu obciążenia (c, d)

Rozbudowanie wektora wejściowego sieci wymagało zwiększenia liczby neuronów warstwy ukrytej. W przypadku wektora \mathbf{X}_1 zastosowano 11 neuronów tej warstwy, natomiast dla wektora \mathbf{X}_2 przyjęto 17 neuronów. Wybrane wyniki badań przedstawiono na rysunku 5. Uzyskano dużą dokładność odtwarzania prędkości w przypadku dynamicznych zmian sygnałów zadanych.

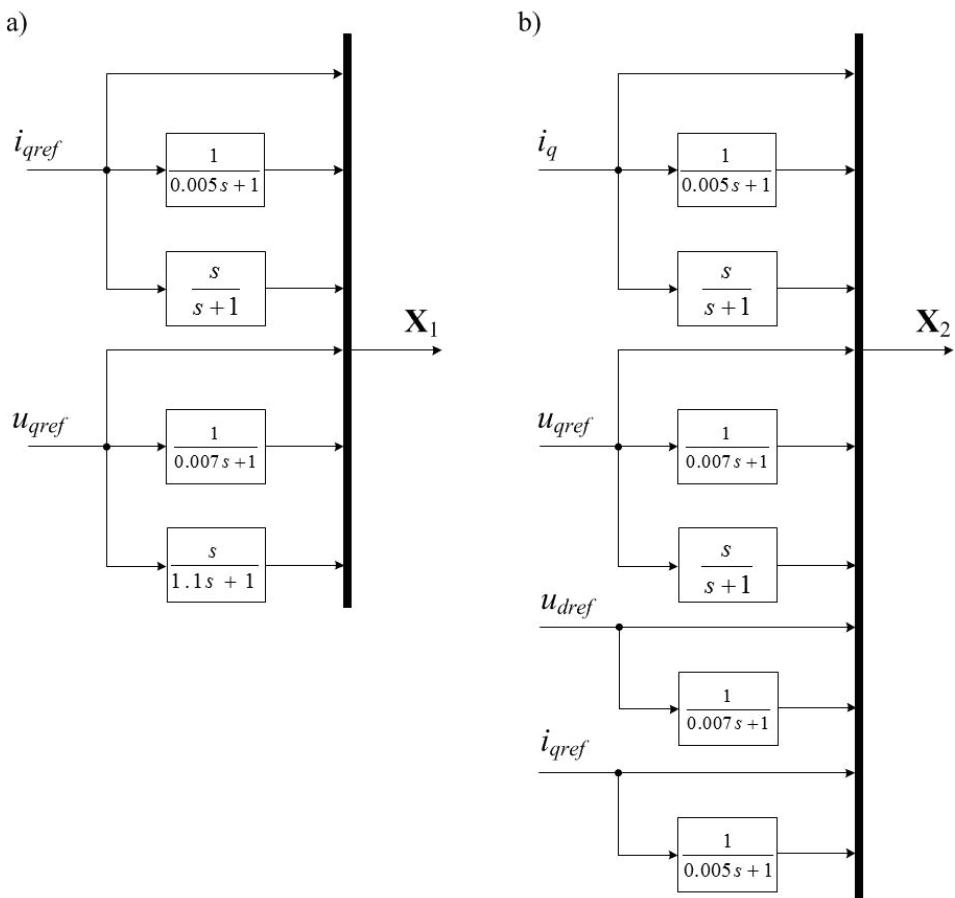
Na podstawie analizy wyników można wywnioskować, że rozbudowanie wektora wejściowego przy jednoczesnym zwiększeniu liczby neuronów w warstwie ukrytej spowodowało poprawę odtwarzania prędkości przy występowaniu momentu obciążenia. W celu porównania obu metod obliczono błędy estymacji prędkości układu napędowego, według poniższej zależności:

$$\delta\omega = \frac{1}{n} \sum_{i=1}^n |\omega_i - \omega_{test}|, \quad i = 1, 2, \dots, n \quad (5)$$

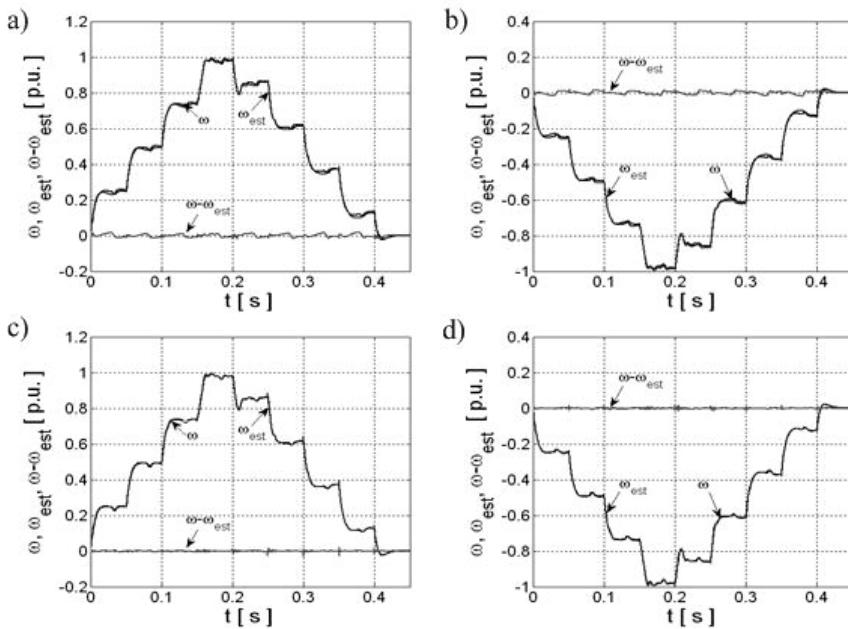
gdzie:

- ω – rzeczywista wartość prędkości układu napędowego,
- ω_{est} – estymowana wartość prędkości układu napędowego,
- n – liczba próbek.

W obliczeniach uwzględniono wartości próbek pomiarowych pochodzących z obu kierunków pracy układu napędowego dla poszczególnych przypadków. Wyniki obliczeń zestawiono w tabeli 2.



Rys. 4. Schematy układów przygotowania wektorów wejściowych neuronowego estymatora prędkości



Rys. 5. Przebiegi rzeczywiste, estymowane oraz różnica wartości chwilowych z zastosowaniem wektora wejściowego X_1 (a, b) oraz X_2 (c, d)

Tabela 2. Zestawienie wartości błędów estymacji

Wektor wejściowy	$\delta\omega$ [p.u.]
X_1	0,0069
X_2	0,0017

5. PODSUMOWANIE

W artykule przedstawiono zagadnienia związane z zastosowaniem sztucznych sieci neuronowych do estymacji prędkości napędu z silnikami synchronicznymi o magnesach trwałych. Zaprezentowano strukturę sterowania oraz rozpatrzono dwa układy formowania wektorów wejściowych sieci neuronowej. Z zaprezentowanych wyników widać dokładną estymację prędkości przez obie struktury. W przypadku zastosowania rozszerzonego wektora wejściowego X_2 oraz struktury sieci neuronowej uzyskano wyższą jakość estymacji prędkości silnika, niż przy wykorzystaniu wektora wejściowego X_1 i struktury sieci neuronowej z nim związanej.

W dalszych pracach przewiduje się rozbudowanie wektora wyjściowego sieci o kąt położenia wirnika, niezbędny do transformat oraz zamknięcie struktury sterowania.

LITERATURA

- [1] BOSE B.K., *Neural Network Applications in Power Electronics and Motor Drives*, IEEE Transactions on Industrial Electronics, Vol. 54, No. 1, 2007, 14–33.
- [2] DYRCZ K., ORŁOWSKA-KOWALSKA T., *Induction motor speed and flux estimation using extended Kalman filter algorithm*, Archives of Electrical Engineering, Vol. LII, No. 3, 2003, 269–290.
- [3] ELBULUK M.E., TONG L., HUSAIN I., *Neural-Network-Based Model Reference Adaptive Systems for High-Performance Motor Drives and Motion Controls*, IEEE Transactions on Industry Applications, Vol. 38, No. 3, 2002, 879–886.
- [4] HORI Y., SAWADA H., CHUN Y., *Slow resonance ratio control for vibration suppression and disturbance rejection in torsional system*, IEEE Transactions on Industrial Electronics, Vol. 46, No. 1, 1999, 162–168.
- [5] ORŁOWSKA-KOWALSKA T., *Bezczujnikowe układy napędowe z silnikami indukcyjnymi*, Oficyna Wydaw., PWr, Wrocław, 2003.
- [6] ORŁOWSKA-KOWALSKA T., SZABAT K., *Neural-network application for mechanical variables estimation of a two-mass drive system*, IEEE Transaction on Industrial Electronics, Vol. 54, No. 3, 2007, 1352–1364.
- [7] OSOWSKI S., *Sieci neuronowe*, Oficyna wydawnicza Politechniki Warszawskiej, Warszawa 1994.
- [8] SZABAT K., ORŁOWSKA-KOWALSKA T., *Adaptive control of two-mass system using nonlinear extended kalman filter*, 32nd Annual Conference on IEEE Industrial Electronics, IECON'06, 2006, 1539–1544.
- [9] ZAWIRSKI K., *Sterowanie silnikiem synchronicznym o magnesach trwałych*, Wydawnictwo Politechniki Poznańskiej, Poznań 2005.

APPLICATION OF NEURAL NETWORKS FOR STATE VARIABLES ESTIMATION
OF DRIVE WITH PERMANENT MAGNET SYNCHRONOUS MOTOR

In this paper analysis of possibilities of neural network application for estimation of speed of permanent magnet synchronous motor is presented. In order to realize of this task *Multi Layer Perceptron Neural Network* are applied. Several design steps with particular emphasis on the selection of structure of neural network and organization of the input vector are described. Chosen results for prepared neural estimator are presented. High precision of speed estimation is obtained. Additionally changes of stator resistance are introduced during tests, even in such case reproduction of this state variable is very precise, tested model is robust. Calculations related to prepared model are realized in Matlab.