

Implementacja nieliniowego obserwatora neuronowego dla napędu elektrycznego o złożonej części mechanicznej

Streszczenie. Przedmiotem analizy, opisanej w niniejszym artykule, jest zmodyfikowany obserwator zmiennych stanu. W modelu wprowadzono dodatkowy element – sieć neuronową, której parametry optymalizowano w trybie on-line. Zadaniem struktury neuronowej jest identyfikacja składowych równań obserwatora, odpowiadających za nieliniowe zjawiska w części mechanicznej napędu. Rezultaty badań (symulacyjnych oraz eksperymentalnych) wykazują skuteczność kompensacji oddziaływania elementów nieliniowych napędu.

Abstract. The subject of analysis, described in this paper, is modified state variables observer. Algorithm contains additional element – neural network with internal weights optimized in on-line mode. The task for neural model is identification of the components (related to nonlinear phenomena in the mechanical part of the drive) used in equations of the observer. The results of tests (simulation and experimental) show effective compensation of the nonlinear elements impact. (**Implementation of nonlinear neural observer for electric drive with complex mechanical part**).

Słowa kluczowe: obserwator nieliniowy, adaptacja parametrów, kompensator neuronowy, układ dwumasowy.

Keywords: nonlinear observer, parameters adaptation, neural compensator, two-mass system.

Opis tematyki

Odniesienie rozważań teoretycznych, w zakresie automatyki napędu elektrycznego (propozycje regulatorów lub metod obliczania zmiennych stanu), do implementacji przemysłowych jest często problematyczne lub utrudnione ze względu na nieliniowy charakter obiektów. Modele liniowe posiadają istotne ograniczenia, wynikające z jedynie liniowej kombinacji sygnałów wejściowych, w reprezentacji pewnej grupy zjawisk. W takich przypadkach należy wprowadzać algorytmy nieliniowe, jednak pojawiają się problemy ze złożoną analizą takich układów regulacji napędów elektrycznych. Poza tym, występuje konieczność wykonania dodatkowych zadań dotyczących identyfikacji członów nieliniowych [1]-[3]. Ponadto, należy pamiętać o możliwych zmianach zjawisk nieliniowych w trakcie eksploatacji napędu. W związku z tym, korzystne wydaje się wprowadzanie dodatkowych elementów modyfikujących przetwarzanie danych w obserwatorach zmiennych stanu wykorzystujących równania obiektu. W takich zadaniach, biorąc pod uwagę powyższe założenia, interesującym rozwiązaniem jest aplikacja modeli neuronowych, szczególnie zakładająca adaptację wag sieci realizowaną w trakcie działania całej struktury (*on-line*). W wyniku obliczeń algorytmu optymalizacyjnego, najczęściej opartego o wyznaczenie gradientu funkcji celu względem dostrajanych parametrów, korygowane są współczynniki sieci, w efekcie czego generowane są wartości wyjściowe stanowiące uzupełnienie dla standardowych obliczeń obserwatora [4]. Sieć neuronowa, w początkowej fazie działania całego układu, dostosowuje się do kompensowania wpływu nieliniowości napędu. Warto podkreślić, że część adaptacyjna realizuje założenia bez dodatkowych obliczeń wstępnych (na postawie losowych współczynników początkowych). Analogiczne rozwiązania spotykane są również w odniesieniu do kompensacji pracy regulatorów układów napędowych [5], [6].

Poniżej przedstawiono przegląd rozwiązań dotyczących obserwatorów nieliniowych, jednak uprzednio należy zaznaczyć, że w zastosowaniach związanych z napędem elektrycznym, połączenie algorytmicznych obserwatorów zmiennych stanu oraz modeli adaptacyjnych inspirowanych teorią sztucznej inteligencji (sieci neuronowych oraz struktur rozmytych), stosowano również w celu uzyskania innych właściwości. Skuteczną współpracę, uproszczonego modelu neuronowego (*Adaptive Linear Neuron*) z adaptacyjnym obserwatorem prędkości (opartym o model

odniesienia) zastosowanym dla liniowego silnika indukcyjnego, przedstawiono w artykule [7]. Uzyskano wysoką dokładność obliczeń dla małych wartości prędkości, którą zachowano nawet w obecności przełączeń momentu obciążenia. Innym rozwiązaniem jest zastosowanie modelu rozmytego w sterowaniu dynamiką obserwatora Luenbergera. Poprzez zwiększanie wartości w macierzy wzmocnień, w stanach przejściowych, zapewniono możliwość szybkiej redukcji błędu. Natomiast w stanie ustalonym pracy napędu, parametry obserwatora są zmniejszane w celu uniknięcia wzmocnienia szumów pomiarowych. Jak wspomniano, powyższe założenia są realizowane poprzez model rozmyty [8]. W kolejnych publikacjach, zastąpiono tą część obserwatora poprzez zastosowanie sieci neuronowej o zmiennych współczynnikach wagowych. W ten sposób uproszczona została część projektowa (poprzez automatyczne dostrajanie sieci) [9].

Opisane przykłady wprowadzania adaptacyjnych modeli neuronowych do obliczeń obserwatorów prezentują możliwości zwiększania precyzji odtwarzania sygnałów lub rozwiązania praktycznych problemów implementacyjnych. Oddzielną grupę aplikacji stanowią hybrydowe układy tego typu dedykowane obiektom nieliniowym. Najczęściej nieliniowa funkcja jest uwzględniona, w reprezentacji obiektu oraz obserwatora, w równaniach stanu poprzez wprowadzenie odpowiednich elementów w tzw. macierzy wejściowej (sterowań) [10]. Jednak w literaturze spotykane są również przypadki opisów neuronowych obserwatorów, w których założeniem jest wyizolowana nieliniowość. Taka postać równania stanu uwzględnia oddzielny element reprezentujący funkcję nieliniową. Pod warunkiem obserwowalności, możliwe jest przeprowadzenie skutecznej identyfikacji za pomocą regresyjnej sieci neuronowej GRNN (*General Regression Neural Network*) [11]. Opisy propozycji nieliniowych obserwatorów różnicują różne typy stosowanych sieci neuronowych, wśród nich znaczną grupę zajmują aplikacje oparte o modele z radialnymi funkcjami aktywacji [12]-[14]. Poprawa działania adaptacyjnych części obserwatorów zmiennych stanu uzyskiwana jest poprzez zwiększoną reprezentację zjawisk dynamicznych, która jest otrzymywana dzięki wewnętrznym sprzężeniom zwrotnym oraz elementom, które pamiętają poprzedni stan układu [15]. Jednak, ze względu na mniej złożone obliczenia, dominująca część implementacji sieci neuronowych dla obiektu nieliniowego wykorzystuje popularne modele

perceptronowe (jednokierunkowe). W wyjątkowych zastosowaniach aproksymacja neuronowa jest realizowana za pomocą dwóch sieci [16]. Algorytmy treningowe, wyznaczające wagi sieci, w wielu przypadkach, wykorzystują dwukierunkowe przetwarzanie sygnałów w modelu (*backpropagation*) aby uzyskać korektę dla kolejnej epoki. Jednak również w tym zakresie stosowane są rozwinięcia klasycznego algorytmu gradientowego, polegające na wprowadzaniu dodatkowych członów w wyznaczaniu poprawek współczynników, które mają zwiększyć efektywność adaptacji [17]. Inną propozycją, która poprawia odtwarzanie przebiegów dynamicznych, jest przekształcenie obserwatora do postaci ułamkowego rzędu [18]. Poza rozwojem algorytmu obserwatora, publikacje przedstawiają także opisy implementacji związane z napędami elektrycznymi: dla silnika indukcyjnego [19], manipulatora przemysłowego [20] lub w diagnostyce uszkodzeń [21], [22].

Zjawiska obserwowane w modelu układu dwumasowego są często analizowane w artykułach naukowo-technicznych. Przedstawiają one problemy związane ze sterowaniem napędów spotykanych w aplikacjach przemysłowych, reprezentatywnymi przykładami są: połączenie pomiędzy turbiną wiatrową oraz generatorem [23], układy sterowania antenami oraz teleskopami [24], analiza dynamiki ruchu w napędach robotów [25], pojazdy z napędem elektrycznym [26], itd. Przy założeniu dużych wartości nastaw regulatorów, wprowadzanych w celu zwiększenia dynamiki systemów przemysłowych, sprężystość elementów sprzęgających stanowi istotne zakłócenie dla układu sterowania [27]. Zagadnienia związane z odtwarzaniem sygnałów są szczególnie istotne dla tego specyficznego napędu, ponieważ najczęściej tłumienie drgań skrętnych jest uzyskiwane poprzez struktury sterowania wykorzystujące dodatkowe zmienne stanu [28]. Powyższy fakt uzasadnia prace przedstawione w niniejszym artykule, które dotyczą zastosowania neuronowego obserwatora zmiennych stanu dla nieliniowego napędu elektrycznego z połączeniem sprężystym. Założeniem, dla opisanych badań, było zaprezentowanie obserwatora neuronowego niezależnie od struktury sterowania. Zatem, testy przeprowadzono w układzie otwartym, uzyskiwane przebiegi nie były wprowadzane do regulatora.

Publikacja składa się z pięciu głównych części tematycznych. Pierwszy rozdział przedstawia grupę rozwiązań, w których połączono klasyczną postać obserwatora z modelem sieci neuronowej o zmiennych parametrach. Następnie zaprezentowano założenia teoretyczne dotyczące zmodyfikowanego obserwatora. Kolejne dwie sekcje związane są z testami obserwatora neuronowego - przebiegi zmiennych stanu otrzymano w badaniach symulacyjnych, a następnie podjęta została próba aplikacji algorytmu dla obiektu rzeczywistego. Ostatni fragment zawiera podsumowanie zrealizowanych zadań projektu oraz główne konkluzje wynikające z uzyskanych wyników.

Model matematyczny obserwatora neuronowego

Obiektem, dla którego zastosowano obserwator neuronowy, jest napęd elektryczny zawierający sprężyste sprzęgło. Ze względu na niewielkie wartości stałych czasowych obwodu elektromagnetycznego, w porównaniu do części mechanicznej, założono bezzwłoczne kształtowanie momentu m_e . Równania różniczkowe opisujące poszczególne zmienne stanu mają następującą postać (dla wewnętrznego współczynnika tłumienia $d=0$):

$$(1) \quad \frac{d\omega_1(t)}{dt} = \frac{1}{T_1}(m_e(t) - m_s(t) - m_{f1}(t)),$$

$$(2) \quad \frac{d\omega_2(t)}{dt} = \frac{1}{T_2}(m_s(t) - m_l(t) - m_{f2}(t)),$$

$$(3) \quad \frac{dm_s(t)}{dt} = \frac{1}{T_c}(\omega_1(t) - \omega_2(t)),$$

gdzie: $m_s(t)$ – moment skrętny, $m_e(t)$ – moment elektromagnetyczny, $m_{f1}(t)$ – moment tarcia silnika, $m_{f2}(t)$ – moment tarcia maszyny roboczej, $\omega_1(t)$ – prędkość silnika, $\omega_2(t)$ – prędkość maszyny roboczej, $m_l(t)$ – moment obciążenia.

W dalszym zapisie wprowadzono założenia upraszczające $m_{f1}(t)=m_{f2}(t)=m_f(t)$. Moment tarcia maszyn opisuje poniższe równanie [29]:

$$(4) \quad m_f(t) = B_m \omega + C_m \text{sign}(\omega),$$

gdzie: B_m – współczynnik tarcia wiskotycznego, C_m – współczynnik tarcia Coulomba, ω – prędkość napędu.

W związku z obliczeniami macierzowymi, przedstawionymi w dalszej części artykułu, dla zależności (1)-(3) wprowadzono równania stanu:

$$(5) \quad \frac{d}{dt}x(t) = Ax(t) + \Xi(x, u),$$

$$(6) \quad \frac{d}{dt} \begin{bmatrix} \omega_1(t) \\ \omega_2(t) \\ m_s(t) \end{bmatrix} = \begin{bmatrix} 0 & 0 & -\frac{1}{T_1} \\ 0 & 0 & \frac{1}{T_2} \\ \frac{1}{T_c} & -\frac{1}{T_c} & 0 \end{bmatrix} \begin{bmatrix} \omega_1(t) \\ \omega_2(t) \\ m_s(t) \end{bmatrix} + \begin{bmatrix} \frac{1}{T_1} & 0 & -\frac{1}{T_1} \\ 0 & -\frac{1}{T_2} & -\frac{1}{T_2} \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} m_e(t) \\ m_l(t) \\ m_f(t) \end{bmatrix},$$

gdzie: Ξ – funkcja opisująca nieliniowości układu dwumasowego.

W (6) uwzględniono tylko tarcie silnika, oczywiście nie jest to jedyne źródło nieliniowości modelu. Jednak należy zauważyć, że reprezentacja wszystkich zjawisk nieliniowych w modelu napędu elektrycznego (np. luz połączenia, część związana z układami energoelektronicznymi, itp.) jest kłopotliwa w zapisie matematycznym, a także wymaga dodatkowej identyfikacji elementów nieliniowych. Poza tym, dalsza synteza regulatorów lub obserwatorów jest bardziej złożona. W wielu aplikacjach, w teoretycznych rozwiązaniach wykorzystywany jest model liniowy, wpływ nieliniowości jest weryfikowany w badaniach na obiekcie rzeczywistym [28], [30]. W opisywanym przypadku, jest to mniej istotne, ponieważ wprowadzono neuronowy system adaptacyjny, który dostraja się w trakcie pracy napędu, bez konieczności uprzedniego wyznaczania parametrów części nieliniowej, w ten sposób uzyskano również pewną uniwersalność aplikacyjną.

Dla układu dwumasowego opisanego równaniami (1)-(3) zaproponowano neuronowy obserwator zmiennych stanu w postaci:

$$(7) \quad \frac{d}{dt}\hat{x}(t) = A\hat{x}(t) + NN(\hat{x}(t), u(t)) + L[y(t) - \hat{y}(t)],$$

$$(8) \quad \hat{y}(t) = C\hat{x}(t),$$

gdzie:

$$(9) \quad \hat{x} = [\omega_{1e} \quad \omega_{2e} \quad m_{se} \quad m_{le}]^T,$$

$$(10) \quad u = m_e,$$

$$(11) \quad y = \omega_1,$$

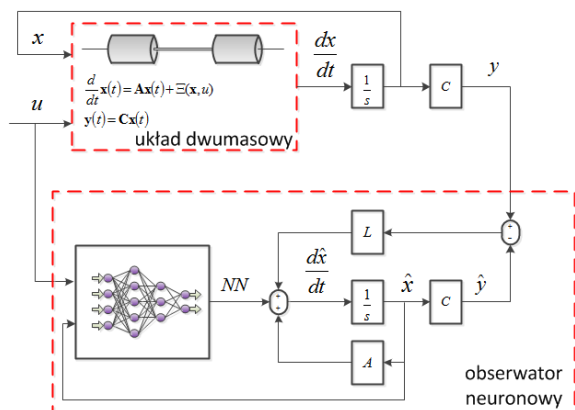
$$(12) \quad \hat{y} = \omega_{1e},$$

indeks e wskazuje na wartości estymowane.

Ideę aplikacji przedstawiono na rysunku 1. Macierz wzmocnień L jest dobierana tak, aby wszystkie wartości własne wyznaczone dla:

$$(13) \quad A_0 = A - LC,$$

posiadały ujemną część rzeczywistą.



Rys.1. Obserwator neuronowy

Model neuronowy uwzględniony w równaniu (7) zawiera jedną warstwę ukrytą:

$$(14) \quad NN(\hat{x}(t), u(t)) = f_o(W_o f_h(W_i[\hat{x}(t) \quad m_e(t)])),$$

gdzie: f_o – liniowa funkcja aktywacji, W_o – macierz współczynników wagowych pomiędzy warstwą ukrytą oraz wyjściową, W_i – wejściowa macierz wag, f_h – funkcja sigmoidalna:

$$(15) \quad f_h(n) = \frac{2}{1 + e^{-2n}} - 1,$$

gdzie: n – argumenty funkcji aktywacji.

Przy założeniu obliczeń w trybie *on-line*, istotną zaletą (ułatwieniem) implementacyjną może być wprowadzenie macierzy W_i w postaci jednostkowej [17]. Natomiast, adaptacja wartości macierzy W_o jest realizowana według zależności:

$$(16) \quad W_o(k+1) = W_o(k) + \Delta W_o(k),$$

$$(17) \quad \Delta W_o(k) = -\alpha \frac{\partial E(k)}{\partial W_o(k)},$$

gdzie: α – współczynnik adaptacji, k – numer iteracji algorytmu, E – funkcja celu zdefiniowana jako:

$$(18) \quad E(k) = \frac{1}{2}(y(k) - \hat{y}(k))^2 = \frac{1}{2}(e(k))^2 = \frac{1}{2}(\omega_1(k) - \omega_{1e}(k))^2.$$

Wstawiając (18) do (17) wyznaczona została pochodna:

$$(19) \quad \Delta W_o(k) = -\alpha \left(\frac{\partial E(k)}{\partial e(k)} \frac{\partial e(k)}{\partial \hat{x}(k)} \frac{\partial \hat{x}(k)}{\partial W_o(k)} \right),$$

kolejne składowe równania (19) obliczone zostały następująco:

$$(20) \quad \frac{\partial E(k)}{\partial e(k)} = e(k),$$

$$(21) \quad \frac{\partial e(k)}{\partial \hat{x}(k)} = \frac{\partial (y(k) - \hat{y}(k))}{\partial \hat{x}(k)} = \frac{\partial (Cx(k) - C\hat{x}(k))}{\partial \hat{x}(k)} = -C,$$

$$(22) \quad \frac{\partial \hat{x}(k)}{\partial W_o(k)} = \frac{\partial \hat{x}(k)}{\partial NN(k)} \frac{\partial NN(k)}{\partial W_o(k)}.$$

W równaniu (22) drugi czynnik można rozwinąć jako:

$$(23) \quad \frac{\partial NN(k)}{\partial W_o(k)} = \frac{\partial f_o(W_o f_h(W_i[\hat{x}(t) \quad m_e(t)]))}{\partial W_o(k)} = f_h(W_i[\hat{x}(t) \quad m_e(t)]).$$

Zapisując (7) w postaci iteracyjnej:

$$\begin{aligned} \hat{x}(k+1) &= A\hat{x}(k) + NN(k) + L[y(t) - \hat{y}(t)] \\ &= A\hat{x}(k) + NN(k) + Ly(t) - L\hat{y}(t) \\ (24) \quad &= A\hat{x}(k) + NN(k) + Ly(t) - LC\hat{x}(t), \\ &= (A - LC)\hat{x}(k) + NN(k) + Ly(t) \\ &= A_0\hat{x}(k) + NN(k) + Ly(t) \end{aligned}$$

możliwe jest wyznaczenie:

$$(25) \quad \frac{\partial \hat{x}(k+1)}{\partial NN(k)} = A_0 \frac{\partial \hat{x}(k)}{\partial NN(k)} + I.$$

Zakładając poprawną estymatę uzyskiwaną w stanie ustalonym, zapisano równanie:

$$(26) \quad \frac{\partial \hat{x}(k+1)}{\partial NN(k)} = \frac{\partial \hat{x}(k)}{\partial NN(k)}.$$

Powyższą zależność wprowadzono do (25):

$$(27) \quad \frac{\partial \hat{x}(k)}{\partial NN(k)} = A_0 \frac{\partial \hat{x}(k)}{\partial NN(k)} + I,$$

po kolejnych przekształceniach:

$$(28) \quad (I - A_0) \frac{\partial \hat{x}(k)}{\partial NN(k)} = I,$$

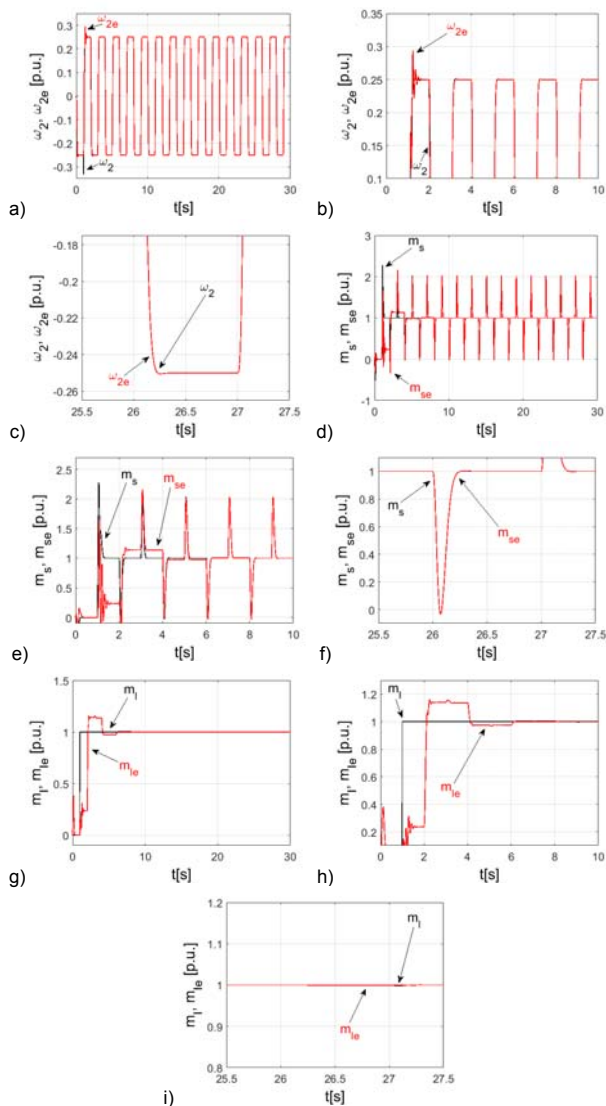
$$(29) \quad \frac{\partial \hat{x}(k)}{\partial NN(k)} = (I - A_0)^{-1} I.$$

Wstawiając równania (20)-(23) oraz (29) do (19) wyliczono korektę wag zapisanych w macierzy W_o dla poszczególnych cykli działania napędu (kroków obliczeniowych). Stabilność powyższych założeń została opisana oraz udowodniona w publikacjach [10]-[21].

Symulacje

W celu wstępnej weryfikacji założeń teoretycznych opisanych w poprzedniej części publikacji, przeprowadzono badania symulacyjne dla modelu układu dwumasowego (6) oraz neuronowego obserwatora zmiennych stanu (7)-(8), (14), (16)-(17). Przyjęto następujące wartości stałych czasowych, zgodne z wynikami identyfikacji zestawu laboratoryjnego, $T_1 = T_2 = 203\text{ms}$ oraz $T_c = 1,2\text{ms}$. Pierwsze uzyskane wyniki miały na celu ogólne zaprezentowanie poprawności działania obserwatora. Cykliczne nawroty napędu testowano przez relatywnie długi czas przeprowadzanych obliczeń, w ten sposób zweryfikowano w sposób praktyczny stabilność działania obserwatora neuronowego. Na rysunku 2 zamieszczono rezultaty dotyczące trzech analizowanych sygnałów związanych z układem dwumasowym: prędkości obciążenia (rysunki 2a-2c), momentu skrętnego (rysunki 2d-2f) oraz momentu obciążenia (rysunki 2g-2i). Poza tym, w celu lepszej

reprezentacji rezultatów wprowadzono rysunki zawierające powiększone fragmenty (rysunki 2b, 2c, 2e, 2f, 2h, 2i). Obserwowalna jest początkowa faza związana z dostrajaniem modelu neuronowego, trwająca około dwóch nawrotów silników. Po tym czasie, sieć uzyskuje zdolność do aproksymacji części nieliniowej napędu, natomiast estymowane przebiegi są wyznaczone precyzyjnie.




Rys.2. Przebiegi zmiennych stanu napędu elektrycznego z połączeniem sprężystym – rzeczywiste oraz obliczone przez obserwator neuronowy

W równaniu (5) funkcja \mathcal{E} uwzględnia nieliniowości układu dwumasowego (a także załączany moment obciążenia). W eksperymencie efekt ten wynikał z naturalnych właściwości silników. Jednak w pozostałych symulacjach (oprócz przebiegów zamieszczonych na rysunku 2) w artykule przyjęto $B_m=C_m=0$, jest to związane z założeniami dotyczącymi zwiększenia przejrzystości wyników oraz braku konieczności identyfikacji nieliniowości rzeczywistego napędu.

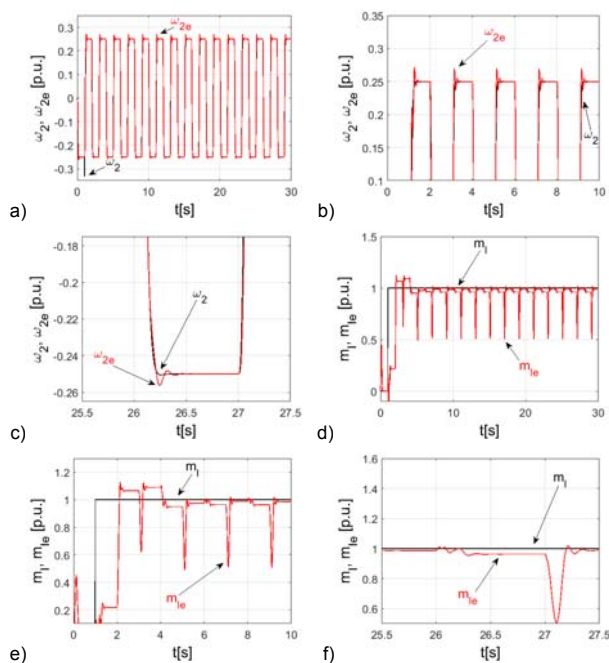
Na czas redukcji błędu treningowego sieci neuronowej znacząco wpływa wartość współczynnika adaptacji α , który skaluje wartości wprowadzanych korekt (17). Zwiększanie tego parametru powoduje wzrost przyrostu wag, przez co uzyskiwane jest szybsze dostrajanie modelu neuronowego. W przebiegu momentu obciążenia (rysunek 3) zredukowano w ten sposób czas, po którym sieć poprawnie

kompensuje zjawiska nieliniowe. Zbyt duża wartość α może jednak powodować mniejszą precyzję przy małych wartościach błędu, a nawet utratę stabilności.




Rys.3. Odtwarzanie momentu obciążenia dla różnych wartości współczynnika adaptacji α

Dodatkowym założeniem prezentacji neuronowego obserwatora zmiennych stanu, jest również przedstawienie zagadnień praktycznych, które związane są z aplikacją dla rzeczywistego napędu elektrycznego. W tym zakresie, w zastosowaniach modeli neuronowych dla rozwiązań inżynierskich, charakterystycznym elementem są obliczenia realizowane na etapie aktywacji neuronów. Najczęściej stosowane są, przynajmniej dla warstw ukrytych, funkcje sigmoidalne. Ważnym warunkiem uzyskania poprawnego działania sieci, jest zapewnienie wykonywania obliczeń w części odpowiadającej największej zmienności wartości. Dlatego korzystnym rozwiązaniem jest wprowadzenie skalowania przetwarzanych danych. W analizowanym rozwiązaniu również zastosowano takie działanie (rysunek 2). Istotność tego zagadnienia, uzasadniają przebiegi wybranych zmiennych stanu - prędkości obciążenia (rysunki 4a-4c) oraz momentu obciążenia (rysunki 4d-4f). Przy znacznych wartościach argumentów, możliwe jest utknięcie w zakresie skrajnych wartości (należy pamiętać o asymptotycznym charakterze takich funkcji oraz ograniczonej dokładności reprezentacji liczb w układach cyfrowych). W takim przypadku mogą występować przełączenia pomiędzy skrajnymi sygnałami wyjściowymi neuronów, w efekcie cała struktura nie wylicza precyzyjnie wartości wyjściowej.



Rys.4. Przebiegi prędkości obciążenia (a)-(c) oraz momentu obciążenia (d)-(f) – brak skalowania danych przetwarzanych przez sieć neuronową

Innym problemem, związanym z użyciem sieci neuronowych, jest wpływ wartości początkowych W_{init} , na otrzymywane wyniki (najczęściej przyjmowane są liczby losowe). Poza zakłóceniami w trakcie rozruchu, może to być istotne dla poprawnej analizy porównawczej. Znaczenie stanu początkowego obserwatora neuronowego dla uzyskiwanych przebiegów przedstawiono na przykładzie momentu obciążenia (rysunek 5). Przeprowadzono trzy testy z różnymi wagami inicjalizującymi działanie algorytmu adaptacyjnego (W_{init1} , W_{init2} , W_{init3}). W badanym zakresie, wartości losowe z rozkładu normalnego różnicowały precyzję działania obserwatora w początkowej części testów. Jednak, poza nieznacznymi zmianami czasu trwania etapu dostrajania sieci neuronowej, ostatecznie obserwator działał bardzo podobnie w poszczególnych badaniach.




Rys.5. Wpływ początkowych wartości współczynników wagowych sieci neuronowej na odtwarzanie momentu obciążenia m_1

Badania eksperymentalne

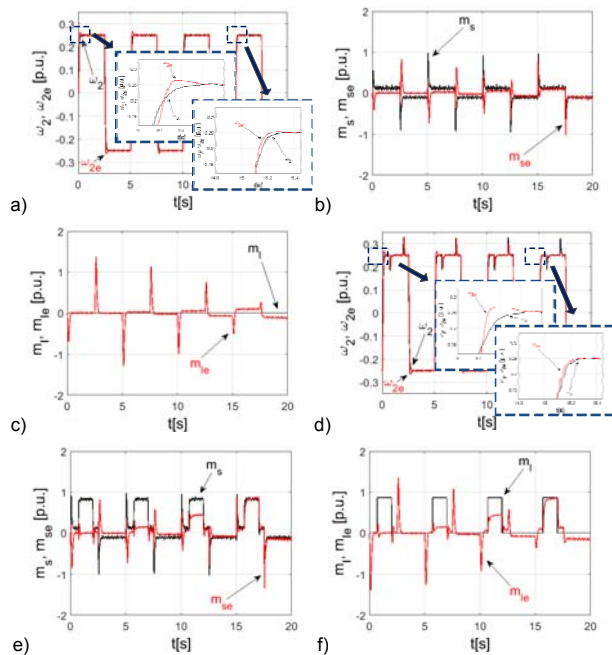
Badania laboratoryjne przeprowadzono na zestawie składającym się z dwóch identycznych silników prądu stałego o mocy 0,5kW (znamionowa prędkość 1450obr./min.). Wybrane elementy napędu zaprezentowano na rysunku 6. Obie maszyny sprzęgnięto za pomocą stalowego łącznika o długości 0,6m. Na wałach zamontowane zostały enkodery, działające w standardzie TTL, monitorujące prędkości układu z rozdzielczością 36000 impulsów generowanych w trakcie pełnego obrotu. Część energoelektroniczna jest zasilana z sieci, składa się z prostownika diodowego (do którego podłączono obwody wzbudzenia obu silników) oraz mostka H (wykorzystywanego do zasilania twornika silnika napędzającego). Drugi element uzyskano poprzez odpowiednie połączenie konfigurowalnego falownika. Twornik maszyny roboczej jest zasilany poprzez klucz tranzystorowy. Całość jest sterowana z karty dSPACE1103.



Rys.6. Stanowisko laboratoryjne



Rys.7. Symulacje przeprowadzone w karcie dSPACE1103




Rys.8. Przebiegi rzeczywistych oraz odtwarzanych, przez obserwator neuronowy, zmiennych stanu w układzie napędowym – brak obciążenia (a)-(c) oraz przełączanie pracy maszyny roboczej (d)-(f)

Badania eksperymentalne zostały podzielone na dwie części, w pierwszym etapie przetestowano działanie nieliniowego obserwatora po aplikacji do procesora karty dSPACE1103. Analizowany model obserwatora neuronowego wykonywał obliczenia na podstawie sygnałów z zaimplementowanego modelu obiektu (nie wykorzystywano sygnałów pomiarowych z silników). Precyzując, wykonano krótkie symulacje sprzętowe realizowane w układzie programowalnym, których celem

było sprawdzenie poprawności działania obserwatora po przeniesieniu z komputera PC do procesora sygnałowego. Wykonywany algorytm został zapętlony, na przedstawionym fragmencie (rysunek 7) widoczna jest wysoka dokładność obliczeń, odpowiadająca symulacjom komputerowym.

Wyniki zamieszczone na rysunku 8, dotyczą odtwarzania wszystkich analizowanych zmiennych stanu (prędkości obciążenia, momentu skrętnego oraz momentu obciążenia) przez obserwator neuronowy, w którym przyjęto losowe wartości początkowe wag, sieć nie była wstępnie dostrajana. W testach założono dwa stany pracy napędu: bez obciążenia (rysunki 8a-8c) a następnie w obecności przetwórcy maszyny roboczej (rysunki 8d-8f). Wymuszony poziom prędkości jest równy 25% wartości znamionowej. Przyjęto prostokątny kształt sygnału zadanego, zatem napęd wykonywał kolejne nawroty. W obu przypadkach, wyraźnie obserwowalny jest czas potrzebny na adaptację modelu neuronowego. Po tej fazie pracy obserwatora zmienne stanu są wyznaczone bardzo dokładnie.



Rys.9. Odtwarzanie prędkości obciążenia (a)-(c) oraz momentu skrętnego (d) przy różnych wartościach współczynnika adaptacji α

Na rysunku 9 zaprezentowano wybrane przebiegi – prędkości ω_2 (rysunki 9a-9c) oraz momentu skrętnego (rysunek 9d), które przedstawiają oddziaływanie współczynnika uczenia na właściwości obserwatora neuronowego. Dla prędkości obciążenia, zamieszczono dodatkowo powiększone fragmenty wykresów (rysunki 9b, 9c). Podobnie jak w symulacjach, wraz ze wzrostem parametru α , zwiększany jest krok obliczeń optymalizatora wagi sieci neuronowej, zatem układ szybciej dąży do minimum funkcji celu (dla kolejnych rozruchów napędu wprowadzono identyczne wartości początkowe wag sieci neuronowej). Warto zwrócić uwagę na mniejszy poziom współczynnika α w porównaniu do testów obliczeniowych. W tym przypadku kolejne wartości dobrano doświadczalnie, w celu uwidocznienia zależności, a także redukcji wpływu zakłóceń pomiarowych.

Podsumowanie

Zwiększanie niezawodności elektrycznych układów napędowych oraz założenia związane z redukcją kosztów realizacji urządzeń, determinują kierunek badań dotyczący metod odtwarzania zmiennych stanu. Dlatego wspomniana tematyka stanowi istotne zadanie w pracach dotyczących rozwoju algorytmów oraz implementacji sprzętowych. Wprowadzanie elementów sztucznej inteligencji, takich jak sieci neuronowe lub modele rozmyte, do algorytmicznych obserwatorów sygnałów struktur sterowania napędu, jest motywowane najczęściej poprawą dynamiki, zwiększeniem odporności na zmiany parametrów obiektu oraz

kompensovaniem zjawisk nieliniowych obiektu lub innych zakłóceń zewnętrznych. W opisanej pracy zastosowano sieć neuronową w celu wyznaczania kolejnych wartości macierzy nieliniowego obserwatora zmiennych stanu. Obiektem był napęd elektryczny z połączeniem sprzężystym. Analizowany obserwator neuronowy działa bardzo precyzyjnie. Nie wykonywano dodatkowych wstępnych obliczeń związanych z nieliniowymi elementami napędu elektrycznego. Właściwości zaobserwowane w badaniach symulacyjnych są analogiczne do działania układu w warunkach laboratoryjnych.

Autor: dr hab. inż. Marcin Kamiński, Politechnika Wroclawska, Katedra Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, Polska, E-mail: marcin.kaminski@pwr.edu.pl.

LITERATURA

- [1] Vaidyanathan S., Volos Ch., *Advances and applications in nonlinear control systems*, Springer, (1996)
- [2] Slotine J.-J.E., Li W., *Applied nonlinear control*, Pearson, (1991)
- [3] Khalil H.K., *Nonlinear control*, Pearson Higher Education, (2014)
- [4] Khojani M.R.R., Ghasemi R., Neural estimation using a stable discrete-time MLP observer for a class of discrete-time uncertain MIMO nonlinear systems, *Nonlinear Dynamics*, 84 (2016), n. 4, 2517-2533
- [5] Pajchrowski T., Wójcik A., Kompensacja momentu zaczepowego w napędzie z silnikiem PMSM z wykorzystaniem sterowania z uczeniem iteracyjnym, *Przegląd Elektrotechniczny*, 94 (2018), n. 5, 128-132
- [6] Hu C., He S., Zhu Y., Wang Z., Yao B., Desired compensation neural network adaptive robust control of an industrial linear motor motion system with comparative experimental investigation, *IEEE International Conference on Information and Automation (ICIA)*, (2016), 479-484
- [7] Cirrincione M., Accetta A., Pucci M., Vitale G., MRAS Speed observer for high-performance linear induction motor drives based on linear neural networks, *IEEE Trans. Power Electronics*, 28 (2013), n. 1, 123-134
- [8] Szabat K., Tran-Van T., Kamiński M., A modified fuzzy luenberger observer for a two-mass drive system, *IEEE Trans. Industrial Informatics*, 11 (2015), n. 2, 531-539
- [9] Kamiński M., Adaptacyjny-neuronowy obserwator Luenbergera zastosowany w estymacji zmiennych stanu układu dwumasowego, *Przegląd Elektrotechniczny*, 90 (2014), n. 6, 79-82
- [10] Liu D., Huang Y., Wang D., Wei Q., Neural-network-observer-based optimal control for unknown nonlinear systems using adaptive dynamic programming, *International Journal of Control*, 86 (2013), n. 9, 1554-1566
- [11] Strobl D., Lenz U., Schroder D., Systematic design of stable neural observers for a class of nonlinear systems, *Proceedings of the IEEE International Conference on Control Application*, (1997), 377-382
- [12] Hua C., Yu C., Guan X., Neural network observer-based networked control for a class of nonlinear systems, *Neurocomputing*, 133 (2014), 103-110
- [13] Liu Y.-J., Tong S.-C., Wang D., Li T.-S., Chen C.L.P., Adaptive neural output feedback controller design with reduced-order observer for a class of uncertain nonlinear SISO systems, *IEEE Trans. Neural Networks*, 22 (2011), n. 8, 1328-1334
- [14] Chen M., Ge S.S., Adaptive neural output feedback control of uncertain nonlinear systems with unknown hysteresis using disturbance observer, *IEEE Trans. Industrial Electronics*, 62 (2015), n. 12, 7706-7716
- [15] Sanchez E.N., Alanis A.Y., Loukianov A.G., *Discrete-time high order neural control*, Studies in Computational Intelligence, Springer, (2008)
- [16] Huang S.N., Tan K.K., Lee T.H., Further result on a dynamic recurrent neural-network-based adaptive observer for a class of nonlinear systems, *Automatica*, 41 (2005), n. 12, 2161-2162
- [17] Abdollahi F., Talebi H.A., Patel R.V., A stable neural network observer with application to flexible-joint manipulators, *Proceedings of the 9th International Conference on Neural Information Processing - ICONIP '02*, 4 (2002), 1910-1914

- [18] Sharafian A., Ghasemi R., Fractional neural observer design for a class of nonlinear fractional chaotic systems, *Neural Computing and Applications*, 31 (2019), n. 4, 1201-1213
- [19] Lakhali A. N., Tlili A. S., Benhadj Braiek N., Neural network observer for nonlinear systems application to induction motors, *International Journal of Control and Automation*, 2 (2010), n. 1, 1-16
- [20] Abdollahi F., Talebi H.A., Patel R.V., A stable neural network-based observer with application to flexible-joint manipulators, *IEEE Trans. Neural Networks*, 17 (2006), n. 1, 118-129
- [21] Abbaspour A., Aboutalebi P., Yen K.K., Sargolzaei A., Neural adaptive observer-based sensor and actuator fault detection in nonlinear systems: Application in UAV, *ISA Transactions*, 67 (2017), 317-329
- [22] Sobhani-Tehrani E., Talebi H.A., Khorasani K., Hybrid fault diagnosis of nonlinear systems using neural parameter estimators, *Neural Networks*, 50 (2014), 12-32
- [23] Huang Y., Zhang Z., Huang W., Chen S., DC-link voltage regulation for wind power system by complementary sliding mode control, *IEEE Access*, 7 (2019), 22773-22780
- [24] Lukichev D.V., Demidova G.L., PID-type fuzzy adaptive control for two-mass servo-drive system: Design, simulation and experiment, *IX International Conference on Power Drives Systems (ICPDS)*, (2016)
- [25] Nishida Y., Ishii K., Sonoda T., Design principle of two mass jumping system, *IEEE International Conference on Systems, Man and Cybernetics*, (2009), 126-130
- [26] Montonen J.-H., Nevaranta N., Lindh T., Alho J., Immonen P., Pyrhönen O., Experimental identification and parameter estimation of the mechanical driveline of a hybrid bus, *IEEE Trans. Industrial Electronics*, 65 (2018), n. 7, 5921-5930
- [27] Chen Y., Yang M., Long J., Hu K., Xu D., Blaabjerg F., Analysis of oscillation frequency deviation in elastic coupling digital drive system and robust notch filter strategy, *IEEE Trans. Industrial Electronics*, 66 (2019), n. 1, 90-101
- [28] Drózd K., Estimation of the mechanical state variables of the two-mass system using fuzzy adaptive Kalman filter - Experimental study, *IEEE 2nd International Conference on Cybernetics - CYBCONF*, (2015), 455-459
- [29] Kim S., Moment of inertia and friction torque coefficient identification in a servo drive system, *IEEE Trans. Industrial Electronics*, 66 (2019), n. 1, 60-70
- [30] Erenturk K., Fractional-orderPIAD μ and active disturbance rejection control of nonlinear two-mass drive system, *IEEE Trans. Industrial Electronics*, 60 (2013), n. 9, 3806-3813