

Adaptacyjny regulator neuronowy dla układu dwumasowego

Streszczenie. W publikacji opisano adaptacyjny regulator neuronowy zastosowany w sterowaniu prędkością napędu elektrycznego z połączeniem sprzężystym. Algorytm wykorzystuje informację o dwóch zmiennych stanu związanych z układem dwumasowym – prędkości: maszyny napędzającej oraz obciążenia. Zaprezentowane zostały wyniki badań symulacyjnych oraz eksperymentalnych, które wykonano na stanowisku laboratoryjnym z wykorzystaniem karty dSPACE 1103.

Abstract. In this publication adaptive neural controller used for speed control of electrical drive with elastic connection is presented. Analyzed control algorithm is based on two state variables of two-mass system: motor and load speeds. In paper simulations and experimental results (done on laboratory stand using dSPACE1103 card) are presented. (**Adaptive neural controller for two-mass system**).

Słowa kluczowe: regulator neuronowy, adaptacja współczynników wagowych, regulacja prędkości, układ dwumasowy.

Keywords: neural controller, adaptation of weights coefficients, speed control, two-mass system.

Wstęp

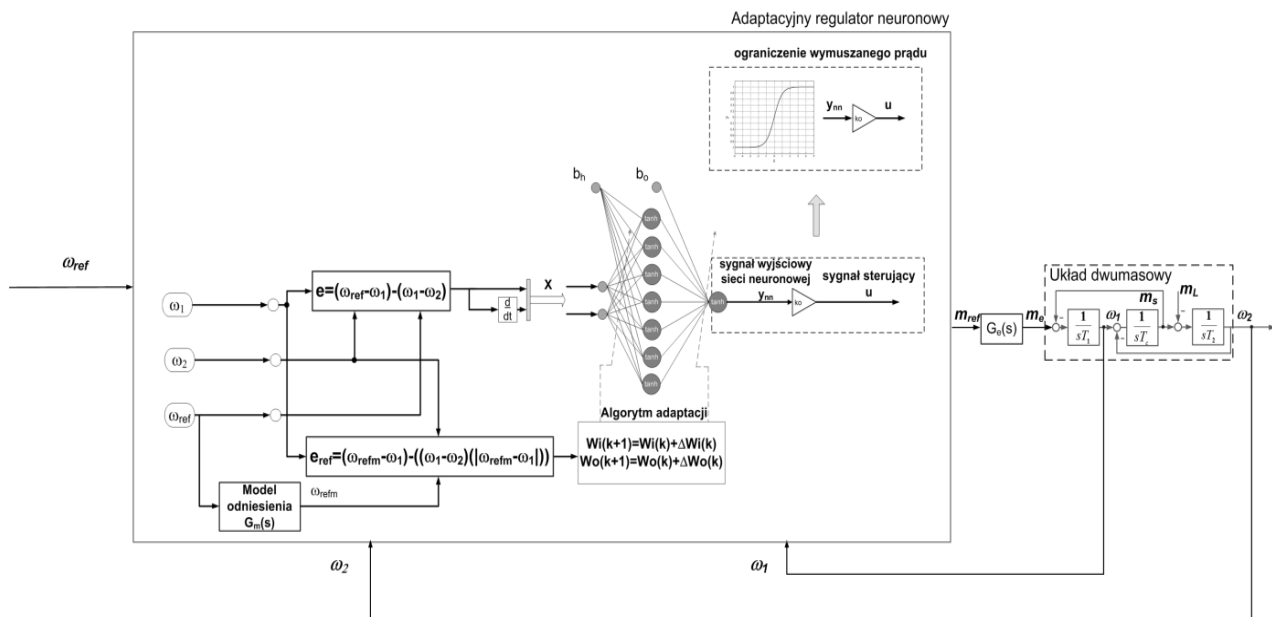
Zagadnienia związane z teorią sterowania, opisywane aktualnie w publikacjach naukowo-inżynierskich, uwzględniają założenia projektowe dotyczące: wzrastających wymagań odnośnie precyzji podążania za trajektorią zadaną, kontroli złożonych obiektów, skuteczności działania systemu w obecności zmian parametrów obiektu oraz możliwości zaprojektowania poprawnie działającego regulatora bez identyfikacji procesu [1], [2]. Jednym z popularnych rozwiązań, stosowanych w układach automatyki, będących odpowiedzią na wymienione wymagania, jest sterowanie adaptacyjne z wykorzystaniem elementów sztucznej inteligencji: logiki rozmytej lub sztucznych sieci neuronowych [3], [4]. Obserwowany trend jest możliwy dzięki intensywnemu rozwojowi zagadnień teoretycznych związanych z tymi dziedzinami, który rozpoczął się w ostatnich dekadach poprzedniego wieku. Jednak obecnie, poza kolejnymi opisami struktur stosowanych modeli oraz sposobów doboru ich parametrów, coraz częściej przedstawiane są oryginalne rozwiązania dotyczące aplikacji sprzętowych (dla różnych obiektów przemysłowych) [5], [6]. Jest to bezpośrednio związane z obniżaniem kosztów elementów elektronicznych, realizujących obliczenia algorytmów. Zastosowania inżynierskie dotyczą wielu dziedzin, wśród nich liczną grupą są napędy elektryczne [7], [8].

W sterowaniu napędami z połączeniem elastycznym stosowane są nowoczesne algorytmy lub regulatory klasyczne rozszerzone o wprowadzane dodatkowe sprzężenia zwrotne z sygnałami: momentu skrętnego oraz prędkości obciążenia [9], [10]. Charakterystyczną cechą takich struktur jest konieczność pomiaru lub odtwarzania dodatkowych zmiennych stanu związanych z układem dwumasowym. Zakładając redukcję czujników pomiarowych, informacje o zmiennych stanu uzyskiwane są za pomocą specjalnych algorytmów estymujących (np. filtr Kalmana) [9], [11], [12], [13]. Możliwe jest również, przy wprowadzeniu pewnych ograniczeń związanych z dynamiką oraz precyzją sterowania, zastosowanie adaptacyjnych regulatorów prędkości bazujących jedynie na prędkości silnika [14], [15].

W proponowanym rozwiązaniu, w układzie regulacji prędkości zastosowano sieć neuronową, której parametry są przeliczane on-line zależnie od uchybu regulacji. W modelu neuronowym nie zostały wprowadzane dodatkowe sprzężenia wewnętrzne. Szczegóły dotyczące struktury oraz równań opisujących adaptację parametrów sieci neuronowej przedstawiono w dalszej części artykułu. Istotną nowelizacją, w stosunku do analizowanych w innych

aplikacjach, jest wprowadzenie definicji błędu prędkości dla regulatora oraz algorytmu adaptacyjnego, uwzględniającego prędkość silnika oraz różnicę obu prędkości układu dwumasowego. W badaniach przedstawiono wpływ wprowadzenia tego sprzężenia na tłumienie oscylacji obu prędkości napędu, który jest szczególnie widoczny w trakcie przełączania obciążenia. Należy zaznaczyć, że idea działania oraz metodyka projektowania opisywanego regulatora neuronowego, zapewniają uniwersalność aplikacji tego typu regulatorów, mogą być stosowane w układach regulacji prędkości napędów ze sztywnym wałem (bez dodatkowego sprzężenia od prędkości obciążenia) oraz różnymi typami silników.

W niniejszej aplikacji, parametry sieci neuronowej przeliczane są on-line. Testowano również możliwość wykorzystania neuronowego regulatora prędkości dostrajanego off-line na podstawie zgromadzonego uprzednio zbioru danych [16]. Tego typu rozwiązanie umożliwia zredukowanie mocy obliczeniowej wymaganej do działania regulatora neuronowego w układzie napędowym. Proces treningu jest przesunięty do etapu projektowania, jednak w ten sposób odporność układu regulacji jest uzależniona od właściwości generalizacyjnych modelu neuronowego (ściśle powiązanych z np. złożonością struktury modelu). W przypadku regulatora podlegającego adaptacji on-line, poprawność działania w trakcie zmian parametrów obiektu jest uzyskiwana poprzez korekty algorytmu adaptacyjnego działającego równolegle do głównego toru przetwarzania sieci neuronowej. W aplikacjach regulatorów adaptacyjnych dla napędów zawierających złożoną część mechaniczną należy wyodrębnić grupę opartą o klasyczne struktury – PI, PID, a także modele o relatywnie dużej liczbie parametrów przestrajalnych, np. neuronowo-rozmyte oraz neuronowe [17], [18], [19]. Należy zwrócić uwagę na problematyczne zagadnienia dotyczące zastosowań adaptacyjnych regulatorów neuronowych. Wśród nich najistotniejsze związane są z doбором stałych współczynników wprowadzanych w algorytmie adaptacji oraz wartościami wag początkowych. Wiele aplikacji opiera się o doświadczone wyznaczenie tych parametrów. Jednak skutecznym sposobem obliczeń współczynników treningowych jest zastosowanie algorytmów genetycznych [20]. Początkowe wartości regulatorów neuronowych są najczęściej losowane, ewentualnie stosowane są złożone teorie [21], [22]. Praktycznymi wskazówkami w tym etapie projektowania regulatora neuronowego trenowanego on-line są: skalowanie (redukcja) wylosowanych wag oraz wstępny trening sieci neuronowej [23], [24].



Rys. 1. Schemat blokowy modelu układu napędowego z uproszczoną pętlą sterowania momentem elektromagnetycznym

W artykule przedstawiono wprowadzenie dotyczące aplikacji regulatorów adaptacyjnych dla układu dwumasowego. Następnie opisano całą strukturę sterowania. W dalszej części zaprezentowano szczegóły adaptacyjnego regulatora neuronowego oraz metodyki obliczania jego współczynników wewnętrznych. W dalszej części przedstawiono wyniki badań symulacyjnych oraz eksperymentalnych. Publikacja została zakończona krótkim podsumowaniem.

Adaptacyjny regulator neuronowy zastosowany w sterowaniu prędkością układu dwumasowego

Model układu dwumasowego w analizowanym napędzie elektrycznym reprezentuje część mechaniczną, stanowiącą sprężyste połączenie pomiędzy silnikiem a maszyną roboczą. Obiekt jest opisany poniżej przedstawionym równaniem stanu [9], [10], [16]:

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

gdzie: ω_1 – prędkość silnika, ω_2 – prędkość maszyny roboczej, m_s – moment skrotny, m_e – moment elektromagnetyczny, m_L – moment obciążenia, T_1 – mechaniczna stała czasowa silnika, T_2 – mechaniczna stała czasowa obciążenia, T_c – stała czasowa elementu sprężystego.

Opisywany układ zawiera, podobnie jak w kaskadowej strukturze sterowania, dwie pętle regulacji: wewnętrzną (związaną z kształtowaniem prądu) oraz zewnętrzną – dotyczącą prędkości. Założono uproszczenie w reprezentacji wewnętrznego toru regulacji, po przekształceniach według kryterium modułu, możliwe jest zapisanie dla tej części układu następującej transmitancji:

$$(2) \quad G_e(s) = \frac{1}{T_{me}s + 1}$$

gdzie: T_{me} – zastępcza stała czasowa obwodu regulacji prądu.

Pełny schemat struktury sterowania zamieszczono na rysunku 1. W pętli sterowania prędkością zastosowano regulator neuronowy, podlegający adaptacji w trybie on-line.

Poniżej opisano przetwarzanie sygnałów analizowanego regulatora prędkości oraz metodykę adaptacji współczynników wagowych modelu neuronowego. W zależnościach matematycznych przyjęto następujące oznaczenia: H – liczba neuronów ukrytych, I – liczba wejść sieci neuronowej, O – liczba neuronów warstwy wyjściowej (liczba wyjść). W związku z tym sygnał wejściowy h – tego neuronu warstwy ukrytej można opisać następująco:

$$(3) \quad ih_{nh} = \sum_{i=1}^I (W_{hi} X_i) + bh_h$$

W całej strukturze sieci neuronowej przyjęto, dla neuronów, funkcję aktywacji:

$$(4) \quad f(x) = \tanh(\beta x) = \frac{e^{\beta x} - e^{-\beta x}}{e^{\beta x} + e^{-\beta x}}$$

gdzie: β – stała wartość ($\beta > 0$, najczęściej w zakresie (0,1)), x – argument funkcji. Pochodna zastosowanej w regulatorze neuronowym, funkcji aktywacji, jest opisana równaniem:

$$(5) \quad f'(x) = \frac{df}{dx} = \beta(1 - f^2(x))$$

W związku z powyższym wartość wyjściowa h -tego neuronu warstwy ukrytej jest opisana zależnością:

$$(6) \quad yhn_h = f(ihn_h) = \tanh(\beta ihn_h)$$

Uwzględniając powyższe równanie, sygnał wejściowy neuronów wyjściowych może być zdefiniowany poniższą zależnością (dla o -tego neuronu):

$$(7) \quad inn_o = \sum_{h=1}^H (W_{oh} yhn_h) + bo_o$$

dla sieci neuronowej z jednym neuronem w ostatniej warstwie przetwarzania ($o=1, inn_o \rightarrow inn$), sygnał wyjściowy jest obliczany zgodnie z równaniem:

$$(8) \quad ynn = f(inn) = \tanh(\beta inn)$$

W każdej iteracji (k) pracy napędu przeliczane są współczynniki modelu neuronowego:

$$(9) \quad \mathbf{W}_i(k+1) = \mathbf{W}_i(k) + \Delta \mathbf{W}_i(k)$$

$$(10) \quad \mathbf{W}_o(k+1) = \mathbf{W}_o(k) + \Delta \mathbf{W}_o(k)$$

w powyższym zapisie: \mathbf{W}_i – macierz wag pomiędzy warstwą wejściową w ukrytą, \mathbf{W}_o – macierz wag pomiędzy warstwą ukrytą a wyjściową. Wprowadzana poprawka wag jest zdefiniowana następująco:

$$(11) \quad \Delta \mathbf{W}_i(k) = -\alpha \frac{\partial E_k}{\partial \mathbf{W}_i}$$

$$(12) \quad \Delta \mathbf{W}_o(k) = -\alpha \frac{\partial E_k}{\partial \mathbf{W}_o}$$

gdzie: E_k jest funkcja celu (najczęściej definiowana w teorii sieci neuronowych jako błąd średniokwadratowy, w aplikacji związanej ze sterowaniem prędkością napędu minimalizowany jest uchyb regulacji sprecyzowany w dalszej części artykułu).

Precyzując (dla pojedynczego połączenia), dla warstwy wyjściowej można zapisać:

$$(13) \quad \Delta W_{oh} = -\alpha \frac{\partial E_k}{\partial W_{oh}}$$

gdzie (stosując regułę łańcuchową):

$$(14) \quad \frac{\partial E_k}{\partial W_{oh}} = \frac{\partial E_k}{\partial inn_o} \frac{\partial inn_o}{\partial W_{oh}} = \delta_o yhn_h$$

w powyższym wzorze:

$$(15) \quad \delta_o = \frac{\partial E_k}{\partial inn_o} = \sum_{a=1}^o \frac{\partial E_k}{\partial y_p} \frac{\partial y_p}{\partial u} \frac{\partial u}{\partial ynn_a} \frac{\partial ynn_a}{\partial inn_o} = \sum_{a=1}^o \frac{\partial E_k}{\partial ynn_a} \frac{\partial ynn_a}{\partial inn_o} = \sum_{a=1}^o \frac{\partial E_k}{\partial ynn_a} f'(inn_o)$$

gdzie: y_p – wyjście sterowanego obiektu, u – sygnał sterujący.

Analogicznie do powyższych rozważań, aktualizacja wag pomiędzy wejściami a warstwą ukrytą, jest opisana wzorem:

$$(16) \quad \Delta W_{hi} = -\alpha \frac{\partial E_k}{\partial W_{hi}}$$

gradient jest obliczany następująco:

$$(17) \quad \frac{\partial E_k}{\partial W_{hi}} = \frac{\partial E_k}{\partial ihh_h} \frac{\partial ihh_h}{\partial W_{hi}} = \delta_h X_i$$

w powyższym wzorze:

$$(18) \quad \delta_h = \frac{\partial E_k}{\partial ihh_h} = \sum_{b=1}^H \frac{\partial E_k}{\partial inn_o} \frac{\partial inn_o}{\partial yhn_b} \frac{\partial yhn_b}{\partial ihh_h} = \sum_{b=1}^H \delta_o W_{ob} f'(ihh_h)$$

Obliczenia Jakobianu we wzorze (15) w rzeczywistych aplikacjach mogą w sposób istotny zwiększać złożoność obliczeniową algorytmu. W związku z tym w publikacji [25] zaproponowano wprowadzenie aproksymacji dla wyrażenia pochodnej funkcji celu E_k względem wyjścia sieci:

$$(19) \quad \frac{\partial E_k}{\partial ynn_a} = A e_m + B \frac{de_m}{dt}$$

gdzie: A, B – wartości stałe, e_m błąd wykorzystywany w algorytmie adaptacji (obliczany z uwzględnieniem modelu odniesienia). Zatem wzór (15) przyjmuje następującą postać:

$$(20) \quad \delta_o = \frac{\partial E_k}{\partial inn_o} = \sum_{a=1}^o \frac{\partial E_k}{\partial y_p} \frac{\partial y_p}{\partial u} \frac{\partial u}{\partial ynn_a} \frac{\partial ynn_a}{\partial inn_o} = \sum_{a=1}^o \left(A e_m + B \frac{de_m}{dt} \right) \frac{\partial ynn_a}{\partial inn_o}$$

W badaniach zastosowano sieć neuronową o strukturze {2-7-1}, zawierającą siedem neuronów ukrytych oraz jedno wyjście (liczbę neuronów warstwy ukrytej dobrano doświadczalnie, uwzględniając uzyskiwaną dokładność sterowania oraz złożoność obliczeń). Regulator posiadał dwa wejścia, do których wprowadzano sygnał błędu oraz jego pochodnej. Proponowany regulator prędkości nie posiada jawnych elementów całkujących w torze głównym przetwarzania. Jednak astatyzm regulacji prędkości jest zapewniony, poprzez sumowanie (całkowanie) wartości aktualnych oraz wyznaczonej aktualizacji dla wartości wag modelu neuronowego, w części adaptacyjnej.

Zastosowanie adaptacyjnych regulatorów neuronowych (trenowanych on-line) w układach sterowania, w wielu przypadkach jest analogiczne (procedura projektowania). Jednak w opisywanej aplikacji należy zwrócić uwagę na charakterystyczny obiekt, którym jest układ dwumasowy. Przy takiej konstrukcji sterowanego elementu wykonawczego obserwowane jest pojawianie się oscylacji zmiennych stanu, które znacząco utrudniają poprawne działanie struktury. W niniejszej aplikacji zaproponowano, w celu tłumienia drgań skrętnych napędu, wprowadzenie do błędu definiowanego dla regulatora neuronowego, dodatkowej składowej zależnej od prędkości obciążenia układu dwumasowego. W dalszej części artykułu zaprezentowano wpływ opisanej modyfikacji. Sygnał wyjściowy regulatora stanowi przebieg opisany zależnością:

$$(21) \quad e = (\omega_{ref} - \omega_1) - (\omega_1 - \omega_2)$$

W przypadku zastosowania neuronowych regulatorów adaptacyjnych błąd wykorzystywany w układzie adaptacji jest obliczany z wykorzystaniem modelu odniesienia:

$$(22) \quad G_m(s) = \frac{\omega^2}{s^2 + 2\zeta\omega s + \omega^2}$$

gdzie: ξ – współczynnik tłumienia oraz ω – pulsacja rezonansowa. Jest to związane z możliwością prób wymuszania znacznej dynamiki w układzie (większej niż

umożliwiają ograniczenia wynikające z konstrukcji obiektu sterowanego), w takich sytuacjach (występujących przez długi czas pracy napędu) może występować problem rozbiegania się regulatora adaptacyjnego. W związku z powyższym parametry modelu odniesienia determinowane są poprzez stałe czasowe obiektu. W regulatorze neuronowym stosowanym w niniejszej aplikacji błąd użyty w obliczeniach algorytmu adaptacyjnego opisany jest równaniem:

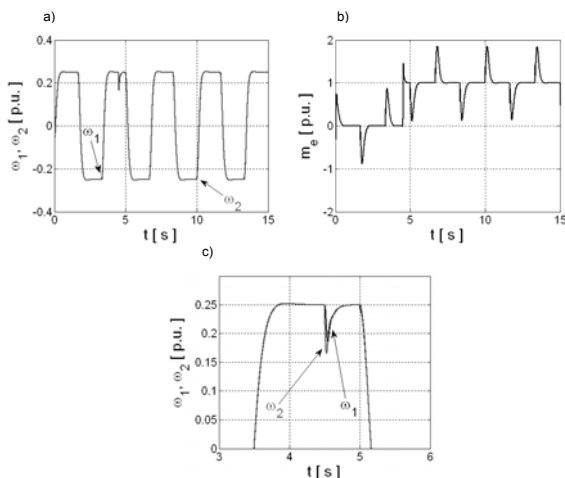
$$(23) \quad e_{ref} = (\omega_{refm} - \omega_1) - ((\omega_1 - \omega_2) \cdot (\omega_{refm} - \omega_1))$$

Wraz z uzyskiwaniem optymalnych parametrów sieci neuronowej, wpływ algorytmu adaptacyjnego jest zmniejszany. W wyniku dostrajania regulatora neuronowego, różnica pomiędzy wartością ω_{refm} oraz ω_1 dąży do zera. W efekcie możliwe jest całkowite zredukowanie błędu obliczanego zgodnie ze wzorem (23). W ten sposób uzyskano stabilizowanie się układu regulacji.

Kolejnym rozwiązaniem konstrukcyjnym adaptacyjnego regulatora neuronowego jest zastosowanie sigmoidalnej wyjściowej funkcji aktywacji. Jest to związane z ograniczaniem prądu w układach napędowych. Wprowadzenie bezpośredniego ograniczenia, przy liniowej funkcji aktywacji może prowadzić do pogorszenia właściwości dynamicznych oraz precyzji sterowania. Zaproponowane rozwiązanie stanowi ograniczenie aktywne (rysunek 1). W trakcie obliczeń wag sieci neuronowej, kształtowania sygnału wyjściowego regulatora, minimalizowany jest błąd z uwzględnieniem obliczeń neuronu wyjściowego. Przyjmując tangens hiperboliczny (4) jako wyjściową funkcję aktywacji możliwe jest dodatkowe skalowanie zadanej wartości momentu elektromagnetycznego poprzez wzmocnienie wyjściowe k_o .

Testy symulacyjne


Model opisanej powyżej struktury sterowania został zaimplementowany w środowisku Matlab\Simulink. Przyjęto krok obliczeniowy równy 0,1ms. Sygnałem zdany dla prędkości napędu był przebieg prostokątny, wymuszający sekwencję zmian kierunku obrotów z prędkością 25% wartości znamionowej. W czasie $t=4,5s$ załączany był znamionowy moment obciążenia. W adaptacyjnym regulatorze neuronowym założono następujące wartości nastaw: $\alpha=0,1$, $A=3$, $B=0,01$, $k_o=4$. Przyjęto następujące wartości parametrów układu dwumasowego: $T_1=T_2=203ms$ oraz $T_c=1,2ms$.



Rys.2. Przebiegi zmiennych stanu w napędzie z adaptacyjnym regulatorem prędkości

Na rysunku 2 zaprezentowano wyniki wstępnych badań analizowanej struktury sterowania. Prędkość jest dynamicznie zmieniana, według trajektorii zadanej. Załączenie momentu obciążenia w układzie powoduje uskok obu prędkości układu dwumasowego z poziomu zadanego. Jednak regulator prędkości wymusza szybkie powrót do wartości referencyjnej poprzez wymuszenie odpowiedniej wartości momentu elektromagnetycznego (rysunek 2b). W celu dokładniejszej obserwacji zachowania napędu w trakcie oddziaływania momentu obciążenia zamieszczono dodatkowe powiększenie wybranego fragmentu przebiegów prędkości: silnika oraz obciążenia (rysunek 2c).

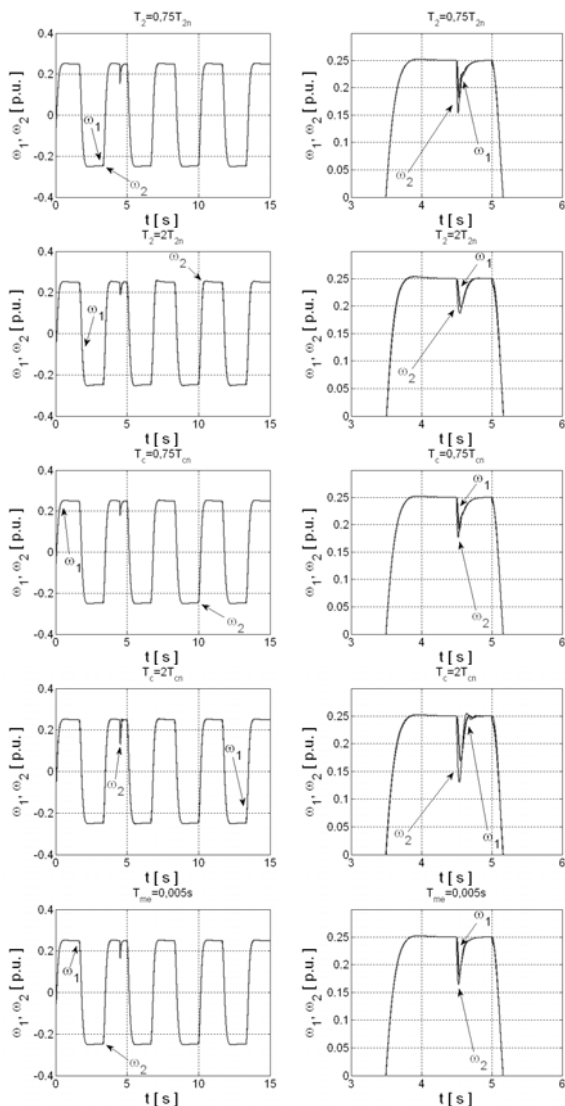
W następnym etapie badań celem było porównanie wpływu wprowadzonego sprzężenia od prędkości obciążenia ω_2 z wynikami uzyskanymi po zastosowaniu adaptacyjnego regulatora neuronowego bazującego jedynie na prędkości pierwszej - ω_1 . W celu obiektywnego porównania należy zaznaczyć, że oba regulatory miały identyczne parametry. We wszystkich badaniach przedstawionych w artykule zastosowano ten sam zestaw wartości początkowych wag sieci neuronowej. Analizując ogólnie przebiegi prędkości (rysunek 3a), można zaobserwować poprawność działania układu regulacji, uzyskane trajektorie są bardzo zbliżone do przypadku z dwoma sprzężeniami zwrotnymi (rysunek 2a). Jednak wpływ zastosowania dodatkowej zmiennej stanu w obliczeniach regulatora istotny jest w chwili przełączania obciążenia, widoczny jest wpływ elastycznego wału, pojawiają się zakłócenia (rysunek 3c). Porównując te przebiegi z wynikami uzyskanymi z wykorzystaniem regulatora z dwoma sprzężeniami, należy stwierdzić, że opisywany regulator zdecydowanie lepiej tłumí oscylacje zmiennej stanu (rysunek 2c).



Rys.3. Przebiegi zmiennych stanu w napędzie z adaptacyjnym regulatorem prędkości realizującym obliczenia na podstawie jednego sprzężenia zwrotnego od prędkości silnika ω_1

Na rysunku 4 zaprezentowano badania opisywanego w artykule układu regulacji z adaptacyjną siecią neuronową włączoną do pętli sterowania prędkością układu dwumasowego. Celem kolejnych symulacji było przetestowanie działania napędu przy zmianach parametrow obiektu. W trakcie badań zmieniano wartości mechanicznych stałych czasowych: maszyny obciążającej T_2 oraz elementu łączącego T_c . W oznaczeniach przyjętych na rysunku 4, symbol n przypisany do oznaczeń stałych czasowych oznacza wartość znamionową danego parametru. Prędkości w napędzie mają bardzo zbliżone przebiegi, nieznaczne różnice widoczne są na powiększonych fragmentach rysunków. W badanym

zakresie zmian parametrów napęd działa poprawnie. Poza tym w ostatnich symulacjach wprowadzono do pętli kształtowania momentu elektromagnetycznego istotne (w porównaniu do rzeczywistych napędów) opóźnienie równe $T_{me}=5ms$. Wszystkie pozostałe przebiegi zmiennych stanu otrzymane w badaniach symulacyjnych wykonano dla idealnej pętli wymuszania momentu elektromagnetycznego – $T_{me}=0s$. Zwiększenie tej stałej czasowej nie wpłynęło znacząco na przebiegi zmiennych stanu. W celu ilościowej oceny pracy regulatora neuronowego wykonano zestawienie błędów sterowania przedstawione w tabeli 1.



Rys.4. Przebiegi zmiennych stanu w napędzie z adaptacyjnym regulatorem prędkości bazującym na dwóch sprzężeniach zwrotnych (od prędkości ω_1 oraz ω_2) – wpływ zmian parametrów napędu

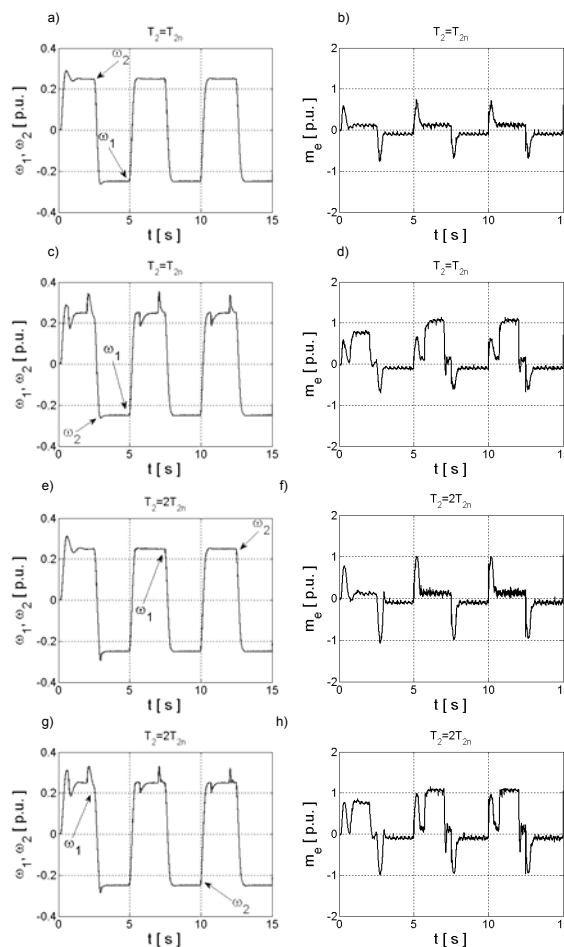
Tabela 1. Błędy neuronowego układu regulacji

	$Err = \frac{1}{N} \left(\sum_{i=1}^N \omega_{ref} - \omega_i \right) \cdot N - \text{liczba próbek}$
$T_2=T_{2n}, T_c=T_{cn}, T_{me}=0s$	0,0528
$T_2=0,75T_{2n}, T_c=T_{cn}, T_{me}=0s$	0,0526
$T_2=1,25T_{2n}, T_c=T_{cn}, T_{me}=0s$	0,0529
$T_2=2T_{2n}, T_c=T_{cn}, T_{me}=0s$	0,0536
$T_2=T_{2n}, T_c=0,75T_{cn}, T_{me}=0s$	0,0527
$T_2=T_{2n}, T_c=1,25T_{cn}, T_{me}=0s$	0,0528
$T_2=T_{2n}, T_c=2T_{cn}, T_{me}=0s$	0,0530
$T_2=T_{2n}, T_c=T_{cn}, T_{me}=0,005s$	0,0527

Eksperyment

Badania eksperymentalne wykonano na stanowisku laboratoryjnym z dwoma silnikami prądu stałego. Należy

jednak zaznaczyć, że zaproponowany układ regulacji może być efektywnie zastosowany w napędzie z silnikami indukcyjnymi, w strukturze z dynamicznym wymuszaniem momentu elektromagnetycznego. W trakcie badań eksperymentalnych zmieniano wartość stałej czasowej T_2 . W rzeczywistym obiekcie modyfikację wartości tego parametru uzyskano poprzez zamontowanie dodatkowych elementów obciążających wał maszyny roboczej. Szczegóły stanowiska laboratoryjnego przedstawiono w publikacjach [9], [10], [19]. Jedno z założeń, w trakcie wykonywania aplikacji, dotyczyło realizacji programu w taki sposób, aby możliwe było uzyskanie właściwości popularnych w ostatnich latach technik tzw. rapid prototyping. W związku z tym najistotniejszym celem było skrócenie czasu przejścia od testów obliczeniowych do analizy eksperymentalnej. Proponowany algorytm wraz z obsługą czujników pomiarowych, pętlą kształtowania momentu elektromagnetycznego oraz częścią dotyczącą sterowania urządzeniami zasilającymi zaimplementowano w procesorze sygnałowym karty dSPACE1103. Algorytm opracowano wykorzystując graficzny język programowania wysokiego poziomu – Matlab\Simulink. Jednak część dotycząca regulatora neuronowego zaaplikowana została w postaci skryptu tekstowego. Poprawne skompilowanie tego fragmentu programu dla procesora sygnałowego było możliwe poprzez blok: Embedded MATLAB functions. Obliczenia algorytmu w układzie programowalnym były realizowane z krokiem 0,1ms. Wirtualny panel operatorski wykonano w programie ControlDesk.



Rys.5. Przebiegi zmiennych stanu w napędzie z neuronowym regulatorem prędkości – wyniki badań eksperymentalnych

Wyniki badań zostały zaprezentowane na rysunku 5. Na wykresach obserwowalny jest wpływ algorytmu adaptacji na

przebiegi zmiennych stanu. Początkowe przeregulowania widoczne w obu prędkościach napędu są szybko eliminowane (rysunek 5a,e). Jest to uzyskane poprzez przestrajanie regulatora w kolejnych nawrotach napędu oraz wymuszanie większej wartości prądu w stanach przejściowych (rysunek 5b,f). Przy zwiększonej wartości T_2 przeregulowanie jest większe jednak w krótkim czasie (w kolejnym okresie trajektorii sygnału zadanego) układ działa bardzo podobnie do przypadku ze znamionowymi parametrami napędu. Struktura regulacji zachowuje się analogicznie przy przełączeniach obciążenia. Pomimo dodatkowych zakłóceń prędkości układu dwumasowego podążają coraz dokładniej za sygnałem zadanym (rysunek 5c,g). Zwiększenie stałej czasowej T_2 nie wpływa znacząco na przebiegi prędkości, jednak jest związane z wymuszaniem większej wartości momentu w czasie nawrotów napędu. Charakterystyczną cechą analizowanego układu regulacji jest duża zbieżność obu prędkości układu dwumasowego.

Podsumowanie

W artykule zaproponowano nową strukturę sterowania zastosowaną dla układu dwumasowego. W pętli regulacji zastosowano adaptacyjny regulator prędkości kształtujący sygnał sterujący na podstawie informacji o dwóch zmiennych stanu – prędkości: silnika oraz maszyny roboczej. Na podstawie analizy teoretycznej oraz przedstawionych wyników badań możliwe jest sformułowanie wniosków zamieszczonych poniżej.

- Istnieje możliwość zastosowania modelu sieci neuronowej w adaptacyjnym układzie regulacji prędkości napędu elektrycznego z połączeniem sprzężystym.
- Zaprezentowane wyniki badań przedstawiają możliwość uzyskania wysokiej precyzji sterowania prędkością oraz skuteczne tłumienie oscylacji zmiennych stanu spowodowanych elastycznym sprzęgłem.
- W trakcie projektowania neuronowego regulatora prędkości nie jest konieczna bezpośrednia identyfikacja obiektu (w porównaniu do aplikacji z klasycznymi regulatorami).
- Wprowadzenie dodatkowego sprzężenia zwrotnego w modelu neuronowym powoduje poprawienie skuteczności tłumienia oscylacji zmiennych stanu w stanach przejściowych.
- Analizowany regulator zaimplementowano w procesorze sygnałowym, po czym uzyskane w symulacjach wyniki potwierdzono w badaniach na stanowisku laboratoryjnym.
- Zastosowanie adaptacyjnego regulatora neuronowego wprowadza również ułatwienie dotyczące projektowania, związane z doбором parametrów funkcji wewnętrznych (w porównaniu do innych modeli adaptacyjnych, np. rozmytych).

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

LITERATURA

- [1] Doyle J.C., Francis B.A., Tannenbaum A.R., Feedback Control Theory, Dover Publications, 2009
- [2] Ogata K., Modern Control Engineering, Prentice Hall (5 edition), 2009
- [3] Ross T.J., Fuzzy Logic with Engineering Applications, Wiley (3 edition), 2010
- [4] Suykens J.A.K., Vandewalle J.P.L., de Moor B.L., Artificial Neural Networks for Modelling and Control of Non-Linear Systems, Springer (Softcover reprint of hardcover 1st ed. 1996 edition), 2010
- [5] Jung S., Kim S.S., Hardware Implementation of a Real-Time Neural Network Controller With a DSP and an FPGA for Nonlinear Systems, *IEEE Trans. Ind. Electronics*, 54 (2007), n.1, 265-271
- [6] Ortega-Zamorano F., Jerez J.M., Franco L., FPGA Implementation of the C-Mantec Neural Network Constructive Algorithm, *IEEE Trans. Ind. Informatics*, 10 (2014), n.2, 1154-1161
- [7] Pajchrowski T., Zawirski K., Nowopolski K., Neural Speed Controller Trained Online by Means of Modified RPROP Algorithm, *IEEE Trans. Ind. Informatics*, 11 (2015), n.2, 560-568
- [8] Lee K.-B., Blaabjerg F., An Improvement of Speed Control Performances of a Two-Mass System using a Universal Approximator, *Electrical Engineering*, 89 (2007), n.5, 389-396
- [9] Szabat K., Struktury sterowania elektrycznych układów napędowych z połączeniem sprzężystym, *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej*, (2008) nr 61, Seria: Monografie Nr. 19, Oficyna Wydawnicza Politechniki Wrocławskiej,
- [10] Szabat K., Orłowska-Kowalska T., Vibration Suppression in a Two-Mass Drive System Using PI Speed Controller and Additional Feedbacks—Comparative Study, *IEEE Trans. Ind. Electronics*, 54 (2007), n. 2, 1193-1206
- [11] Serkies P.J., Szabat K., Fuzzy adaptive Kalman filter for the drive system with an elastic coupling, *Archives of Electrical Engineering*, 62 (2013), n.2, 251-265
- [12] Pracownik A., Sieklucki G., Tondos M., Cyfrowy obserwator LQ w układzie 2-masowym, *Elektrotechnika i Elektronika*, 29 (2010), nr 1-2, 14-19
- [13] Erenturk K., Nonlinear two-mass system control with sliding-mode and optimised proportional-integral derivative controller combined with a grey estimator, *IET Control Theory and Applications*, 2 (2008), n. 7, 635-642
- [14] Kaminski M., Neural network speed controller for drive system with elastic joint, *Proc. of Int. Conf. Computer as a Tool*, (2013), 2080-2085
- [15] Szabat K., Direct and indirect adaptive control of a two-mass drive system — a comparison, *Proceedings of the IEEE Int. Symp. Ind. Electronics*, (2008), 564-569
- [16] Kamiński M., Orłowska-Kowalska T., Regulatory neuronowe trenowane off-line zastosowane w strukturze sterowania prędkością napędu dwumasowego, *Przegląd Elektrotechniczny*, 91 (2015), nr 1, 9-12
- [17] Wang H., Zhu S., Liu S., Adaptive PID control of robot manipulators with H^∞ tracking performance, *IEEE/ASME Int. Conf. on Advanced Intelligent Mechatronics*, (2009), 1515-1520
- [18] Yiu Y.K., Li Z.X., PID and adaptive robust control of a 2-DOF over-actuated parallel manipulator for tracking different trajectory, *IEEE Int. Symp. Computational Intelligence in Robotics and Automation*, 3 (2003), 1052-1057
- [19] Knychas S., Szabat K., Zastosowanie adaptacyjnego regulatora opartego na zbiorach rozmytych typu II do sterowania prędkością układu napędowego, *Przegląd Elektrotechniczny*, 87 (2011), nr 4, 160-163
- [20] Lin F.-J., Huang P.-K., Chou W.-D., Recurrent-Fuzzy-Neural-Network-Controlled Linear Induction Motor Servo Drive Using Genetic Algorithms, *IEEE Trans. Ind. Electronics*, 54 (2007), n.3, 1449-1461
- [21] Thimm G., Fiesler E., Neural network initialization, *Int. Workshop on Artificial Neural Networks*, 930 (1995), 535-542
- [22] Fernández-Redondo M., Hernández-Espinosa C., Weight initialization methods for multilayer feedforward, *Proc. European Symposium on Artificial Neural Networks*, 4 (2001), 119-124
- [23] Kaminski M., Orłowska-Kowalska T., Adaptive neural speed controllers applied for a drive system with an elastic mechanical coupling – A comparative study, *Engineering Applications of Artificial Intelligence*, 45 (2015), 152-167
- [24] Reed R.D., Marks R.J., Neural Smoothing - Supervised Learning in Feedforward Artificial Neural Networks, A Bradford Book The MIT Press Cambridge, 1999
- [25] Lin F.-J., Wai R.-J., Hybrid controller using a neural network for a PM synchronous servo-motor drive, *IEE Proc.-Electr. Power Appl.*, 145 (1998), n.3, 223 - 230