

Porównanie struktur regulacyjnych dla napędu bezpośredniego z silnikiem PMSM ze zmiennym momentem bezwładności i obciążenia

Streszczenie. W pracy dokonano oceny efektów implementacji neuronowego regulatora prędkości uczonego w czasie rzeczywistym według algorytmu RPPROP (ang. Resilient backPROPagation) z układem: jednopętlowym WRM (ang. Without Reference Model), dwupętlowym MFC (ang. Model Following Control) i MRAC (ang. Model Reference Adaptive Control) dla napędu bezpośredniego z silnikiem synchronicznym z magnesami trwałymi (ang. PMSM) oraz zmiennym momentem bezwładności i obciążenia w funkcji kąta położenia wału silnika. Przeprowadzono liczne badania symulacyjne i eksperymentalne na podstawie których dokonano oceny właściwości regulacyjnych układu regulacji prędkości obrotowej.

Abstract. The evaluation of the implementation of the real-time neural speed controller according to the RPPROP (Resilient backPROPagation) algorithm was performed with a single-loop WRM (Without Reference Model), MFC (Model Following Control) and Model Reference Adaptive Control (MRAC) for direct drive with PMSM motor with variable inertia and load torque. Numerous simulations and experiments have been performed, the basis of which the control system have been evaluated (**Comparison of control structures for direct drive with PMSM motor with variable inertia and load torque**)

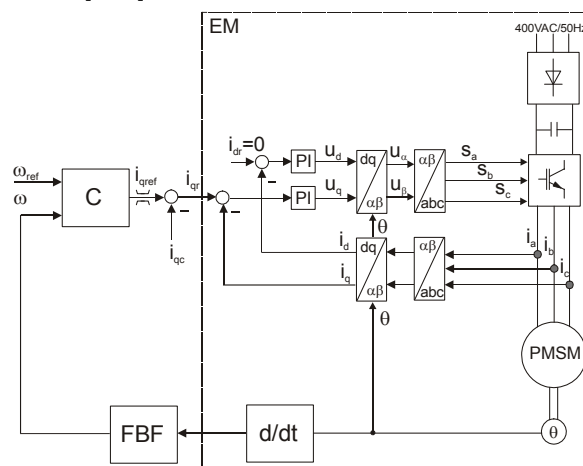
Słowa kluczowe: napęd bezpośredni, regulator neuronowy, MFC, MRAC.

Keywords: direct drive, neural controller, MFC, MRAC.

Wstęp

Napęd bezpośredni to takie rozwiązanie konstrukcyjne w którym silnik elektryczny jest bezpośrednio połączony z maszyną roboczą bez przekładni mechanicznej. Od takiego silnika wymagana jest specjalna konstrukcja, która umożliwia pracę układu napędowego z małymi prędkościami obrotowymi, z reguły nieprzekraczającymi 100 obr./min, a często znacznie niższymi. Wzrost wymagań przemysłowych obserwowany od wielu lat, wymaga stosowania coraz to bardziej precyzyjnych rozwiązań, zwłaszcza w przemysłowych napędach robotów, maszynach technologicznych, na przykład papierniczych, zwijarek czy innych serwonapędach. Brak przekładni mechanicznej wprowadza wiele zalet, takich jak: wyeliminowanie luzów wprowadzanych przez przekładnię, co poprawia dokładność statyczną pracy i poprawia właściwości dynamiczne napędu, zwiększa sprawność układu napędowego (wyeliminowanie strat mechanicznych w przekładni) i niezawodność (mniejsza liczba elementów mechanicznych) [4]. Wymienione zalety napędów bezpośrednich wymagają jednak stosowania odpowiednich algorytmów regulacji w układzie sterowania. W napędzie bezpośrednim moment bezwładności maszyny roboczej jest wielokrotnie wyższy niż moment własny silnika, dlatego duże zmiany momentu bezwładności tej maszyny mają wpływ na warunki pracy układu napędowego (w napędzie klasycznym z przekładnią moment bezwładności przeliczony na stronę silnika ma wartość podobną) [4,10]. W wielu układach napędowych moment bezwładności zależy od kąta położenia wału układu napędzanego. Dlatego zachodzi potrzeba zaprojektowania układu regulacji prędkości lub położenia wykazującego cechy odporności i adaptacyjności na zmiany parametrów mechanicznych obiektu o dobrych właściwościach dynamicznych. Zaproponowanie odpowiednich algorytmów sterowania, odpowiedniego typu regulatora czy struktury układu regulacji, która zapewni uzyskanie przez napęd elektryczny dobrej dynamiki i wysokiej precyzji sterowania jest zadaniem trudnym, którym zajmuje się wiele ośrodków naukowych oraz przemysłowych na świecie [1,5,14,15]. W wielu tych pracach projektanci często odwołują się do metod inteligencji maszynowej (ang. *Computational Intelligence* lub *Soft-Computing*). W syntezy tych układów

regulacji zastosowanie znalazły zwłaszcza takie metody jak: logika rozmyta (ang. *Fuzzy Logic*), sztuczne sieci neuronowe (ang. *Artificial Neural Networks - ANN*) oraz algorytmy genetyczne i ewolucyjne (ang. *Genetic Algorithms, Evolutionary Algorithms*). Schemat badanego napędu wykorzystanego w niniejszej pracy z silnikiem PMSM bez modelu referencyjnego (WRM) pokazano na rys. 1. Zastosowany silnik sterowany jest wektorowo z zachowaniem stałego kąta mocy $\delta = \pi/2$, co odpowiada zerowej wartości prądu w osi d . Analizowany regulator prędkości wylicza wartość zadaną prądu w osi q , która odpowiada zadanemu momentowi elektromagnetycznemu silnika [9,10].




Rys.1. Struktura sterowania silnikiem PMSM (FBF- filtr antyrezonansowy, EM – część elektromechaniczna układu, C- regulator, i_{qref} - sygnał wyjściowy regulatora, i_{qc} - dodatkowe wejście kompensujące tarcie i moment tętający, i_{qr} - prąd zadany)

Pętla regulacji prędkości jest bardzo wrażliwa na zmiany określonych parametrów układu napędowego, takich jak: moment bezwładności, stała momentu elektromagnetycznego czy czas opóźnienia [8,9,10]. Pętla ta może być niewrażliwa na wahania tych parametrów, dzięki odpowiedniej syntezy regulatora prędkości. W wielu ośrodkach badawczych w celu zapewnienia niewrażliwości pętli regulacji prędkości na zmianę parametrów układu

napędowego stosuje się regulatory odporne [5], samostrojące [6,15], adaptacyjne [9,10,11]. Bardzo często ze względu na właściwości uczenia i adaptacji są wykorzystywane sztuczne sieci neuronowe. Stosowane są różne rozwiązania. W pracach [2,3] został wykorzystany model odwrotny napędu. Wadą takiego rozwiązania są problemy związane z wyborem: danych uczących, parametrów uczenia oraz odpowiedniej struktury sieci neuronowej. W [1] zastosowano ANN, aby aktualizować parametry klasycznego regulatora w zależności od zmian parametrów w obiekcie. Dodatkowo bardzo często stosuje się różne struktury, takie jak MRAC [6] czy MFC [5,8]. W wielu z tych pracach zostały wykorzystane metody inteligencji obliczeniowej, gdzie stosowano znany algorytm wstecznej propagacji błędów do uczenia sieci neuronowej. W niniejszej pracy dokonano oceny efektów implementacji neuronowego regulatora prędkości uczonego w czasie rzeczywistym według algorytmu RPROP (ang. Resilient backPROPagation) z układem: jednopętlowym WRM (ang. Without Reference Model), MRAC (ang. Model Reference Adaptive Control) i dwupętlowym MFC (ang. Model Following Control) dla napędu bezpośredniego z silnikiem synchronicznym z magnesami trwałymi (ang. PMSM) oraz zmiennym momentem bezwładności i obciążenia w funkcji kąta położenia wału silnika. Przeprowadzono liczne badania symulacyjne i eksperymentalne na podstawie których dokonano oceny właściwości regulacyjnych układu sterowania prędkością obrotową.

Układ jednopętlowy bez modelu referencyjnego (WRM)

Uproszczony schemat blokowy układu bez modelu referencyjnego w osiach dq został przedstawiony na rys. 2.



Rys.2. Struktura układu jednopętlowego bez modelu referencyjnego (WRM)


Model składa się z trzech bloków głównych: neuronowego regulatora prędkości, uczonego online aktualną wartością błędny regulacji, zamkniętej pętli regulacji momentu elektromagnetycznego $T(s)$ i części mechanicznej ze zmiennym momentem bezwładności $J=f(t,\theta)$. Zamkniętą pętlę regulacji momentu silnika PMSM zapisaną w osiach dq można przedstawić jako:

$$(1) \quad T(s) = \frac{k_T}{1 + sT_i} \cdot e^{-sT_\mu}$$


gdzie: k_T – stała momentu elektromagnetycznego (17,5Nm/A), zidentyfikowane stałe czasowe ($T_\mu=1,3ms$, $T_i=0,7ms$).

Układ jednopętlowy z modelem referencyjnym (MRAC)

Uproszczony schemat blokowy układu jednopętlowego z modelem referencyjnym (MRAC) w osiach dq został przedstawiony na rys. 3. Neuronowy regulator prędkości, uczone jest online aktualną wartością błędny pomiędzy prędkością modelu referencyjnego a rzeczywistą silnika. Struktura tego układu została zaprezentowana na rys. 4,



Rys.3. Struktura układu jednopętlowego z modelem referencyjnym (MRAC)

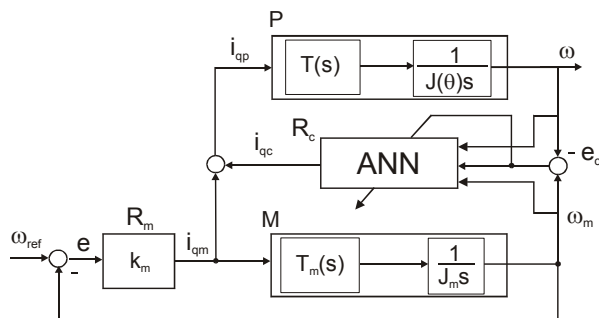


Rys.4. Schemat blokowy modelu referencyjnego

gdzie: $T_m(s)$ – zamknięta pętla regulacji momentu elektromagnetycznego, K_p – wzmacnienie regulatora prędkości, J_m – moment bezwładności.

Układ dwupętlowy z modelem odniesienia (MFC)

Schemat blokowy układu dwupętlowego z modelem referencyjnym w osiach dq został zobrazowany na rys. 5.



Rys.5. Struktura układu dwupętlowego z modelem referencyjnym (MFC); M – model obiektu, P – obiekt rzeczywisty

Neuronowy (ANN) regulator korekcyjny R_c strojony jest wartością błędny pomiędzy prędkością modelu a wartością aktualną prędkości silnika. Zaletą analizowanej struktury MFC jest to, że za pomocą regulatora modelu R_m można kształtować odpowiedź na skok prędkości zadanej, natomiast nastawami regulatora korekcyjnego R_c kształtujemy odpowiedź na zmianę parametrów obiektu. Dla układu MRAC oraz MFC przyjęto model z minimalną stałą wartością momentu bezwładności J_{min} .

Model obiektu do ciągłej zmiany momentu bezwładności i obciążenia

Przy założeniu, że wszystkie części ruchome układu napędowego wirują z tą samą prędkością obrotową, momenty bezwładności są niezmiennicze, wszystkie połączenia są sztywne, wówczas cały układ można potraktować jak bryłę sztywną o stałym momencie bezwładności J . Dla takich założeń równanie ruchu obrotowego można zapisać [4]

$$(2) \quad m - m_L = J \frac{d\omega}{dt}$$

Jeżeli w układzie napędowym założymy brak połączeń sprężystych i zmian energii potencjalnej można zapisać wyrażenie [4]:

$$(3) \quad m_d \omega = \frac{d}{dt} \left(\frac{J \omega^2}{2} \right)$$

a następnie po przekształceniach uzyskać zależność:

$$(4) \quad m_d = J \frac{d\omega}{dt} + \frac{\omega}{2} \frac{dJ}{dt}$$

gdzie: m – moment elektromagnetyczny silnika, m_L – moment obciążenia, m_d – moment dynamiczny.


W układach w których moment bezwładności zależy od kąta obrotu (układy korbowe zamieniające ruch obrotowy na posuwisto zwrotny np. pompy i sprężarki tłokowe, prasy) można zapisać następujące wyrażenie:

$$(5) \quad J(\theta) = J_{const} + J_{var}(\theta)$$


Wówczas po przekształceniach otrzymuje się zależność [4]:

$$(6) \quad m_d = J \frac{d\omega}{dt} + \frac{\omega^2}{2} \frac{dJ}{d\theta}$$

Rozwiązanie równania 5 przedstawiono na rysunku 6.




Rys. 6. Schemat blokowy przedstawiający układ ze zmiennym momentem bezwładności i obciążenia zależnym od kąta obrotu wału




Rys. 7. Schemat poglądowy przedstawiający model obciążenia: a) ze stałym momentem bezwładności i obciążenia; b) ze zmiennym momentem bezwładności i obciążenia (fotografia rys. 8)

W ramach realizowanych prac, został zbudowany model mechaniczny obciążenia, którego zadaniem była ciągła zmiana momentu bezwładności i momentu obciążenia w funkcji zmian położenia wału silnika. Na rysunku 7a zaprezentowano schemat poglądowy modelu obciążenia ze stałym momentem bezwładności dla przypadku, w którym założone są metalowe krążki na obu ramionach. W celu uzyskania zmiennego momentu bezwładności w funkcji kąta należy zdemonstrować metalowe krążki z jednego ramienia. To powoduje, że zmienia się również moment oporowy, który zależy od kąta położenia wału. Taką sytuację ukazują rysunek 7b.



Rys.8. Fotografia przedstawiająca front stanowiska do symultanicznej zmiany momentu bezwładności i momentu obciążenia.1- metalowe krążki do zmiany masy; 2- ramię o zmiennej długości


Na rysunku 9 przedstawiono zmiany momentu bezwładności oraz obciążenia w funkcji kąta obrotu wału. Minimalna wartość J to $1,2 \text{ kgm}^2$ dla -90° (krążki na dole zainstalowane na jednym ramieniu), maksymalna wartość J to $3,8 \text{ kgm}^2$ dla 90° (krążki na górze). Z rys. 9 można odczytać również, że największy moment oporowy osiąga wartość 42 Nm dla 0° i -42 Nm dla $\pm 180^\circ$.



Rys.9. Przebieg momentu bezwładności i obciążenia dla różnych konfiguracji zainstalowanych krążków

Struktura regulatora neuronowego i proces uczenia sieci neuronowej

Na rys. 10 zaprezentowano przyjętą strukturę regulatora neuronowego. Sieć neuronowa ANN posiada trzy wejścia główne dla sygnałów prędkości zadanej (ω_{ref}), prędkości rzeczywistej (ω) i uchybu (e), oraz dodatkowe wejście sygnału prędkości opóźnionej o jeden okres próbkowania, który w układzie wynosi $100 \mu\text{s}$. Sieć posiada dwie warstwy o nieliniowej (tangens hiperboliczny) i liniowej funkcji aktywacji [10], gdzie sygnałem wyjściowym jest prąd zadany w osi q (i_{qref}) dla układu WRM i MRAC oraz korekcyjny w osi q (i_{qc}) dla struktury MFC.



Rys.10. Struktura regulatora neuronowego

Uczenie online sieci neuronowej o dużej dynamice, uwarunkowane jest zastosowaniem szybkiej w realizacji praktycznej procedury uczenia. Stała zdwojenia regulatora T_i została potraktowana jako neuron o liniowej funkcji aktywacji. Do uczenia wybrano algorytm RPROP (ang. Resilient backPROPagation) [7,12,13], którego główną zaletą jest wyliczanie jedynie znaku składowej gradientu,

bez określania jej wartości. W pracach [8,9,10] przedstawiono główne jego zalety, wprowadzając dodatkowe modyfikacje tego algorytmu, które poprawiły jakość uczenia. Procedura uczenia sieci neuronowej zależy od zastosowanej struktury regulacji. Dla układu WRM, błąd według którego uczona jest sieć wynosi:

$$(7) \quad E = \frac{1}{2}(\omega_{ref} - \omega)^2$$

Natomiast dla struktur MRAC i MFC błąd obliczany w każdym kroku próbkowania wynosi:

$$(8) \quad E = \frac{1}{2}(\omega_m - \omega)^2$$

W procesie uczenia sieci zmiana współczynnika wagi $\Delta w_{ij}(k)$ dla j-tego wejścia i i-tego neuronu odbywa się zgodnie z zależnością [12]:

$$(9) \quad \Delta w_{ij}(k) = -\eta_{ij}(k) \cdot \text{sign}\left(\frac{\partial E_k(w(k))}{\partial w_{ij}}\right)$$

W formule (10) zwraca uwagę charakterystyczna cecha metody RPROP, polegająca na tym, że stała uczenia $\eta_{ij}(k)$ jest indywidualnie dobiegana dla każdej wagi a jej wartość jest zmieniana w każdym kroku uczenia. Zmiany stałej uczenia odbywają się według następującej zasady [12]:

$$(10) \quad \eta_{ij} = \begin{cases} \min(a\eta_{ij}(k-1), \eta_{\max}) & \text{dla } S_{ij}(k)S_{ij}(k-1) > 0 \\ \max(b\eta_{ij}(k-1), \eta_{\min}) & \text{dla } S_{ij}(k)S_{ij}(k-1) < 0 \\ \eta_{ij}(k-1) & \text{dla innych przypadków} \end{cases}$$

gdzie η_{\min} , η_{\max} oznacza minimalną i maksymalną wartość współczynnika uczenia, a i b wartości stałe ($a=1,2$, $b=0,5$),

$$(11) \quad S_{ij}(k) = \frac{\partial E_k(w(k))}{\partial w_{ij}}$$


Współczynniki η_{\min} , η_{\max} oraz a i b były takie same dla każdej z analizowanych struktur.

Przeprowadzone liczne badania opisanej struktury regulatora neuronowego i wybranej metody uczenia na laboratoryjnym układzie fizycznym, wykazały potrzebę wprowadzenia do wzoru na zmianę stałej uczenia poprawki w formie strefy nieczułości Δs , gwarantującej w warunkach rzeczywistych sygnałów mierzonych sprzężenia zwrotnego, w obecności zakłóceń, stabilny proces uczenia online [8, 9, 10]. Jednak, poprzez zaproponowaną modyfikację, zawierającą wprowadzenie strefy nieczułości, którą szerzej opisano w pracach [9, 10] jedna z zalet algorytmu RPROP została wyeliminowana. W algorytmie przy rozważaniu niezerowej wartości strefy nieczułości Δs obliczanie wartości funkcji gradientu jest wymagane. W związku z tym komparator, który jest konieczny do określenia znaku funkcji błędu, oblicza także jego wartość. Ponieważ, na podstawie przeprowadzonych testów zaproponowana wartość Δs jest wybierana empirycznie, to pozwala na użycie w algorytmie tylko przybliżonych wartości gradientu. Równanie gradientu funkcji błędu neuronu wyjściowego dla przyjętej struktury sieci neuronowej oraz opis wprowadzonych założeń został przedstawiony w pracach [9, 10]. Ostatecznie zmiany stałej uczenia odbywają się według następującej zasady:


$$(12) \quad \eta_{ij} = \begin{cases} \min(a\eta_{ij}(k-1), \eta_{\max}) & \text{dla } S_{ij}(k)S_{ij}(k-1) > \Delta S \\ \max(b\eta_{ij}(k-1), \eta_{\min}) & \text{dla } S_{ij}(k)S_{ij}(k-1) < -\Delta S \\ \eta_{ij}(k-1) & -\Delta S \leq S_{ij}(k) \cdot S_{ij}(k-1) \leq \Delta S \end{cases}$$

Badania symulacyjne


Badania symulacyjne zostały wykonane w programie Matlab-Simulink. Celem badań było dokonanie oceny efektów implementacji neuronowego regulatora prędkości uczonego w czasie rzeczywistym według algorytmu RPROP z układem: jednopętlowym WRM, MRAC i dwupętlowym MFC ze zmiennym momentem bezwładności i obciążenia w funkcji kąta położenia wału silnika. Dla każdej analizowanej struktury parametry uczenia oraz wagi początkowe były takie same. Pierwsze przedstawione badania symulacyjne przedstawiają wpływ zmian momentu bezwładności dla dwóch skrajnych wartości J_{\min} (1.2kgm^2) i J_{\max} (3.8kgm^2) (rys.11-16). Następnie pokazano zachowanie się analizowanych struktur regulacji z układem mechanicznym o zmiennym momencie bezwładności i obciążenia w funkcji kąta (rys. 17-19)




Rys.11. Przebiegi prędkości: aktualnej, modelu i referencyjnej dla analizowanych struktur podczas procesu uczenia (J_{\min})




Rys.12. Przebiegi prędkości: aktualnej, modelu i referencyjnej dla analizowanych struktur podczas procesu uczenia (J_{\min})




Rys.13. Wartości wskaźnika ISE dla poszczególnych okresów podczas uczenia (J_{\min})




Rys.14. Przebiegi prędkości: aktualnej, modelu i referencyjnej dla analizowanych struktur podczas procesu uczenia (J_{\max})




Rys.15. Przebieg prędkości: aktualnej, modelu i referencyjnej dla analizowanych struktur podczas procesu uczenia (J_{\max})




Rys.16. Wartości wskaźnika ISE dla poszczególnych okresów podczas uczenia (J_{max})



Rys.17. Przebiegi prędkości aktualnej, modelu i referencyjnej dla analizowanych struktur podczas procesu uczenia ($J=f(\theta)$)



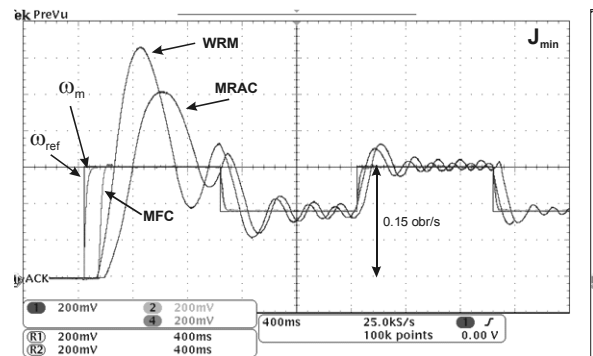
Rys.18. Przebiegi prądu w osi q dla analizowanych struktur podczas procesu uczenia ($J=f(\theta)$) oraz momentu bezwładności



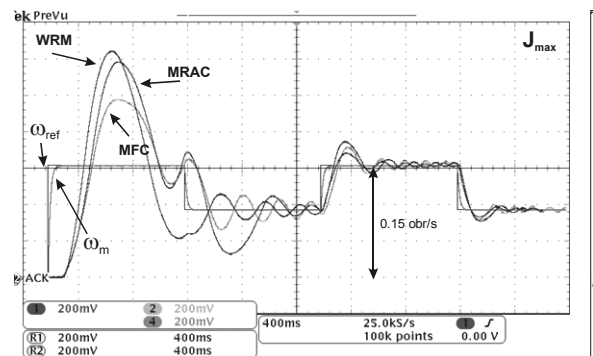
Rys.19. Wartości wskaźnika ISE dla poszczególnych okresów podczas uczenia ($J=f(\theta)$)

Na rys. 11 i 12 zobrazowano przebiegi prędkości aktualnej, modelu i referencyjnej dla analizowanych struktur podczas procesu uczenia z minimalnym momentem bezwładności. Na rys. 13 przedstawiono wartość wskaźnika ISE dla poszczególnych okresów prędkości. Można zauważyć, że najmniejszą wartością tego indeksu charakteryzuje się układ MFC. Na rys. 14 i 15 zaprezentowano analogiczne przebiegi prędkości, ale dla maksymalnego momentu bezwładności. Rys. 16 ukazuje wartość wskaźnika ISE dla poszczególnych okresów prędkości. Można zaobserwować, że również i w tym przypadku najmniejszą wartością wskaźnika charakteryzuje się układ MFC. Porównując wskaźniki ISE dla struktury MFC i skrajnych momentów bezwładności można spostrzec, że na początku procesu uczenia wartość tego wskaźnika jest większa dla układu z J_{max} . Wynika to z tego, że dla tej struktury przyjęto model z minimalnym momentem bezwładności J_{min} . Ponadto, każda z analizowanych struktur zachowuje się prawidłowo podczas procesu uczenia. Następnie przeprowadzono test ze zmiennym momentem bezwładności i obciążenia w funkcji kąta. Na rys. 17 przedstawiono przebiegi prędkości podczas nauki dla analizowanych struktur, a na rys. 18 przebieg prądu w osi q, który jest proporcjonalny do momentu obciążenia oraz przebieg momentu bezwładności, który zmienia się


symultanicznie z momentem obciążenia. Rys. 19 przedstawia indeks jakości ISE dla poszczególnych okresów nauki. Również i w tym przypadku najmniejszą wartością wskaźnika charakteryzuje się układ MFC.



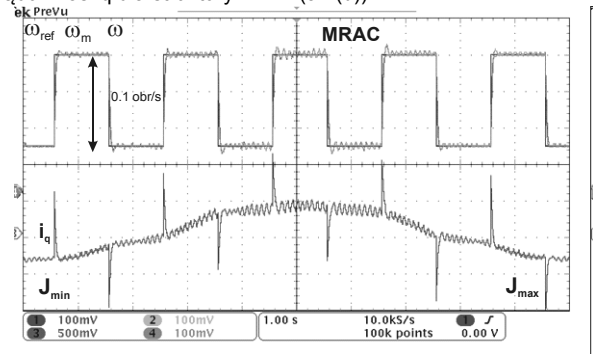
Rys.20. Przebiegi prędkości: zadanej, modelu i rzeczywistej dla analizowanych struktur podczas rozruchu (J_{min}).




Rys.21. Przebiegi prędkości: zadanej, modelu i rzeczywistej dla analizowanych struktur podczas rozruchu (J_{max})




Rys.22. Przebiegi prędkości: zadanej, modelu i rzeczywistej oraz prądu w osi q dla struktury WRM ($J=f(\theta)$)



Rys.23. Przebiegi prędkości: zadanej, modelu i rzeczywistej oraz prądu w osi q dla struktury MRAC ($J=f(\theta)$)



Rys.24. Przebiegi prędkości: zadanej, modelu i rzeczywistej oraz prądu w osi q dla struktury MFC ($J=f(\theta)$)



Rys.25. Porównanie prędkości aktualnej i wskaźnika ISE dla 5-go okresu

Badania eksperymentalne

Wszystkie opisane struktury regulacyjne zostały zaimplementowane na stanowisku laboratoryjnym wyposażonym w procesor sygnałowy ADSP-21060 w środowisku VisualDSP [10]. Czas próbkowania układu mikroprocesorowego wynosił 100 μ s, a częstotliwość pracy falownika PWM wynosiła odpowiednio 10 kHz. Badania eksperymentalne potwierdziły wyniki uzyskane za pomocą badań symulacyjnych.

Podsumowanie

W pracy dokonano oceny efektów implementacji neuronowego regulatora prędkości uczonego w czasie rzeczywistym według algorytmu RPROP z układem: jednopętlowym WRM, MRAC i dwupętlowym MFC dla napędu bezpośredniego z silnikiem synchronicznym z magnesami trwałymi ze zmiennym momentem bezwładności i obciążenia w funkcji kąta położenia wału silnika. Po przeprowadzeniu licznych badań symulacyjnych i eksperymentalnych, na podstawie których dokonano oceny właściwości regulacyjnych układu regulacji prędkości obrotowej można wyciągnąć wniosek, że najmniejszą wartością błędu podczas rozruchu oraz symultanicznej zmiany momentu bezwładności i obciążenia wyróżnił się układ MFC. Niemniej jednak, pozostałe układy zachowywały się poprawnie podczas uczenia i zmiany parametrów napędu.

Autor: dr hab. inż. Tomasz Pajchrowski, Politechnika Poznańska, Instytut Automatyki, Robotyki i Inżynierii informatycznej, ul. Piotrowo 3a, 60-965 Poznań, E-mail: tomasz.pajchrowski@put.poznan.pl;

LITERATURA

- [1] Bose B.K., Chio K.M., Kim H.J., *Self Tuning Neural Network Controller for Induction Motor Drives*, IEEE Annual Conference of the IEEE Industrial Electronics Society, (2002), Vol.1, 152-156.
- [2] Chen D., York M., *Adaptive Neural Inverse Control Applied to Power Systems*, IEEE Power Systems Conference and Exposition, (2006), 2109-2115.
- [3] Colina-Morles E., Mort N., *Inverse Model Neural Network - Based Control of Dynamic Systems*, IEEE Control Conference, (1994), Vol. 2, 955- 960.
- [4] Leonard W., *Control of electrical drives*, Berlin, Heiderberg, Springer-Verlag, (2001).
- [5] Fayez F. M. El-Sousy, *High-Performance Neural-Network Model-Following Speed Controller for Vector-Controlled PMSM Drive System*, IEEE International Conference on Industrial Technology ICIT (2004).
- [6] Lusu Guo, Leila Parsa, *Model Reference Adaptive Control of Five-Phase IPM Motors Based on Neural Network*, *IEEE Transactions on Industrial Electronics*, (2012), vol. 59, no. 3.
- [7] Nguyen D.H., Widrow B., *Neural Networks for Self-Learning Control Systems*, *Control Systems Magazine, IEEE* (April 1990), Volume:10, Issue: 3,.
- [8] Pajchrowski T., *Robust control of PMSM system using the structure of MFC*, *COMPEL: The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, (2011), Vol. 30 Issue: 3, pp.979 – 995.
- [9] Pajchrowski, T., Zawirski, K.: Application of artificial neural network for adaptive speed control of PMSM drive with variable parameters, *COMPEL, The International Journal for Computation and Mathematics in Electrical and Electronics Engineering*, (2013) Vol. 32, No. 4.
- [10] Pajchrowski, K. Zawirski, K. Nowopolski, *Neural Speed Controller Trained Online by Means of Modified RPROP Algorithm*, *IEEE Trans. Ind. Informat.*, (2015), vol. 11, no. 2, pp. 560–568.
- [11] Rahman M.A., Hoque M.A., *On-line adaptive artificial neural network based vector control of permanent magnet synchronous motors*, *IEEE Transactions on Energy Conversion*, (1988), vol. 13, No. 4, pp.311-318.
- [12] Riedmiller M., Braun H., *A direct adaptive method for faster backpropagation learning: The RPROP algorithm*, *IEEE International Conference on Neural Networks* (1993), vol. 1, 28pp. 586-591.
- [13] Rutkowski L., *Computational Intelligence Methods and Techniques*, (2008) Springer-Verlag.
- [14] Mohamed Y.A.-R.I., *Adaptive Self-Tuning speed control for Permanent-Magnet Synchronous Motor Drive with Dead Time*, *IEE Transactions on energy conversion*, (2006) Vol. 21, No. 4.
- [15] Tursini M., Parasiliti F., Zhang D. , *Real-Time Gain Tuning of PI Controllers for High-Performance PMSM Drives*, *IEEE Transactions of Industrial Applications*, (2002) Vol. 38, No. 4,.