

Michał JAKUBOWSKI, Krystian NOWAKOWSKI, Krzysztof ZAWIRSKI

INSTYTUT AUTOMATYKI I INŻYNIERII INFORMATYCZNEJ, POLITECHNIKA POZNAŃSKA,
ul. Piotrowo 3a, 60-965 Poznań

Neuronowy regulator prędkości obrotowej odporny na zmiany bezwładności

Mgr inż. Michał JAKUBOWSKI

Absolwent kierunku Automatyka i Robotyka na Wydziale Elektrycznym Politechniki Poznańskiej.



Mgr inż. Krystian NOWAKOWSKI

Doktorant w Zakładzie Sterowania i Elektroniki Przemysłowej, Instytutu Automatyki i Inżynierii Informatycznej Politechniki Poznańskiej.



e-mail: krystian.m.nowakowski@doctorate.put.poznan.pl

Prof. dr hab. inż. Krzysztof ZAWIRSKI

Profesor w Zakładzie Sterowania i Elektroniki Przemysłowej, Instytutu Automatyki i Inżynierii Informatycznej Politechniki Poznańskiej.



e-mail: krzysztof.zawirski@put.poznan.pl

Keywords: neural controller, neural controlling, artificial intelligence, machine learning, PID.

1. Wprowadzenie

1.1. Neuronowe układy sterowania

Współczesna nauka coraz częściej wyłamuje się z zamkniętych konwenansów matematyki klasycznej szukając nowych efektywniejszych rozwiązań. Wielu badaczy jest głęboko zainspirowanych możliwościami percepcji ludzkiego mózgu. Pewne zadania, takie jak analiza wzorców, sposoby wnioskowania oraz przetwarzania niejasnych lub nieliczbowych danych, mimo ogromnego rozwoju aparatu matematycznego nadal niezwykle ciężko jest przenieść na grunt matematyczny.

Taki stan rzeczy powoduje szerokie zainteresowanie naukowców dziedzinami wiedzy związanymi z inteligencją maszynową, popularnie zwaną sztuczną inteligencją, czyli sposobami naśladowania ludzkiego mózgu przez maszyny. Podobny trend zauważyć można także w automatyce teoretycznej. Równoległe do systemów opartych na logice rozmytej rozwijają się struktury neuronowe. Tematyka zastosowania sztucznych sieci neuronowych do sterowania układów napędowych stanowi problematykę pracy wielu naukowców na całym świecie, czego przykładem mogą być publikacje [1, 2 i 4].

Najpopularniejsze obecnie regulatory typu PID w ogromnej większości swoich zastosowań pracują znacznie lepiej niż sterowanie manualne prowadzone przez człowieka. Są one jednak strojone właśnie na podstawie działań operatorów i starają się ich naśladować dodając jednak wielokrotnie mniejszy czas reakcji i wysoką niezawodność. Stąd też pomysł, aby połączyć ludzki sposób „rozumowania” naśladowany przez sieć neuronową z szybkością i bezbłędnością przetwarzania danych zapewnionymi przez układy elektroniczne. Na połączeniu tych cech znaleźć można właśnie regulatory neuronowe.

1.2. Metodologia prowadzonych badań

Neuronowy regulator prędkości obrotowej, opracowany w ramach niniejszej pracy, zastosowany został do sterowania układu napędowego z silnikiem prądu stałego. Silnik prądu stałego sterowany jest napięciowo, przy pomocy nawrotnego przekształtnika impulsowego. Do przeprowadzonych badań zastosowano silnik o następujących parametrach znamionowych: moc - 56 W, napięcie - 12 V, prąd - 7,3 A, prędkość - 3000 obr/min, moment - 0.15 Nm. Sygnałem zadanym są skoki prędkości obrotowej pomiędzy wartościami 0, 2000, -2000, -1000, 1000 obr/min.

Streszczenie

W ramach niniejszej pracy zaprezentowany został neuronowy regulator prędkości obrotowej odporny na zmiany bezwładności. Celem pracy było opracowanie struktury regulatora oraz dobór optymalnego algorytmu uczenia. Stworzony regulator sterował pracą silnika prądu stałego. Metodologia prowadzonych badań zakładała zbadanie działania układu w szerokim zakresie zmian momentu obciążenia oraz bezwładności. Projektowanie przeprowadzono w taki sposób, aby badany układ napędowy wykazywały dobre właściwości regulacyjne w szerokim zakresie zmiany bezwładności obciążenia. Proces syntezy regulatora został szczegółowo opisany w ramach niniejszej pracy. Analizie poddano szereg badań symulacyjnych, w ramach których rozpatrywano wybrane wskaźniki jakości dla różnych wartości bezwładności oraz momentu obciążenia. Dokonano także analizy porównawczej badanego regulatora neuronowego z optymalnie nastrojonym klasycznym regulatorem PID. Uzyskane wyniki symulacyjne zostały przeniesione na grunt implementacji fizycznego obiektu sterowania.

Słowa kluczowe: regulator neuronowy, sterowanie neuronowe, sztuczna inteligencja, uczenie maszynowe, PID.

A neural speed controller robust to inertia changes

Abstract

This paper presents a neural network speed controller that is robust to inertia changes. The main object of this study was to establish the structure of the controller and to create an optimal learning algorithm. Within the project, the created controller steered the operation of a DC motor. The methodology of the research involved studying the effects of the system over a wide range of load torque and inertia changes. The project was carried out in a such way that good regulatory properties over a wide range of inertia changes were performed for the drive systems. The synthesis of the controller is described in details in this paper. The analysis of series simulation studies including selected quality indicators for different values of inertia and different load torque is conducted. Moreover, the comparative analysis of the neural control and the optimally tuned classical PID controller is performed. The obtained simulation results were used for implementation of a physical control object.

W badanym układzie napędowym możliwa jest zmiana momentu obciążenia silnika oraz bezwładności. Zmianę momentu obciążenia zrealizowano przy użyciu drugiego silnika, połączonego z badanym silnikiem sprzęgłem sztywnym. Zadawano wartości momentu oporowego wynoszące 0, 0,1, -0,1 oraz -0,05 Nm. Zmianę bezwładności uzyskano natomiast przy użyciu krążków zakładanych na wał silnika. Badania przeprowadzono dla trzech różnych wartości bezwładności: małej - 180 gcm², średniej - 5110 gcm² oraz dużej - 6150 gcm².

Do obiektywnego porównania działania regulatorów zastosowano wskaźniki jakości. Wybrane wskaźniki jakości podzielono na dwie grupy: czasowe i całkowite. Czasowe wskaźniki jakości odnoszą się do przebiegu prędkości obrotowej i jej chwilowych wartości przyjmowanych w czasie. Zastosowano następujące wskaźniki:

- t_n – czas narastania do 90% wartości zadanej,
- t_r – czas regulacji, po którym wartość prędkości nie wykracza poza 3% wartości zadanej,
- e_{max} – maksymalna wartość uchybu odnotowana w procesie regulacji po upływie t_n .

Wskaźniki całkowite natomiast opisują proces regulacji w całej jego rozciągłości od momentu wystąpienia ostatniej zmiany sygnału zadane, aż do chwili bieżącej. Zastosowano następujące wskaźniki:

- $ISE = \int_{t_0}^{t_k} e^2 dt$ – całka z kwadratu uchybu,
- $ITSE = \int_{t_0}^{t_k} e^2 \cdot t dt$ – całka z iloczynu kwadratu uchybu i czasu,
- $FM = \int_{t_0}^{t_k} U_s \cdot I_s dt$ – zużycie energii elektrycznej.

2. Synteza regulatorów

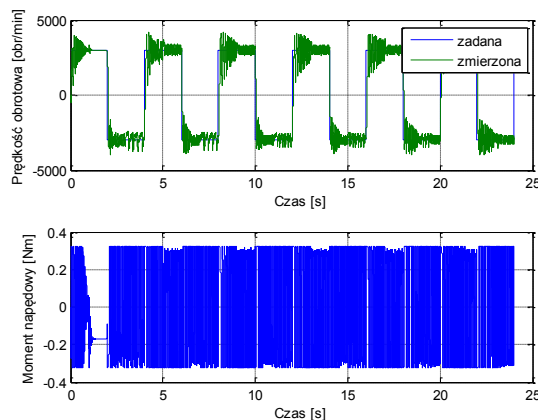
W przedstawionym projekcie sieć była uczona metodą propagacji wstecznej błędu. Początkowe wartości wag x_{ij} dobierane były każdorazowo wg wzoru (1). Inaczej jednak niż w wielu autorów (np. [3, 5]) dobrany został współczynnik uczenia. W realizacji regulatora neuronowego nie istnieje bowiem problem niedostatecznej ilości danych uczących. Bardzo wyraźnym problemem jest natomiast „doutczenie” sieci do wartości chwilowej, co może powodować oscylacje odpowiedzi regulatora, a co za tym idzie całego układu. W związku z powyższym dobierać należy niewielkie wartości współczynnika uczenia, takie jak np. $\eta=0,1$. Jako błąd wykorzystywany w procesie uczenia przyjęty został uchyb regulacji.

$$x_{ij} = \text{rand}\left(-\frac{\sqrt{n_{in}}}{2}, \frac{\sqrt{n_{in}}}{2}\right) \quad (1)$$

Przed rozpoczęciem budowy sieci neuronowej należy podjąć decyzję odnośnie postaci sygnałów wejściowych i wyjściowych. Wyjście wymusza umiejscowienie regulatora w procesie regulacji, będzie nim więc wartość napięcia zasilania silnika. Przy czym wyjście z sieci neuronowej przyjmować będzie wartości z przedziału [-1, 1], a przeskalowanie liniowe następować będzie poza nią. Za wejścia sieci obrano, podobnie do struktur prezentowanych w [5], prędkość zadaną, poprzednią prędkość zmierzona oraz poprzednie napięcie zasilania. Przy czym, ze względu na względną prostotę i liniowość obiektu sterowania używane będą jedynie trzy poprzednie próbki prędkości. Wyjście sieci, podobnie jak w pracach przedstawionych w [5], stanowić będzie neuron liniowy, pozbawiony funkcji aktywacji.


Pierwszy test przeprowadzony został dla sieci o rozmiarze 5-3-1. Jego wynik pokazuje rys. 1. Przeprowadzonych zostało jeszcze wiele testów sieci trójwarstwowych, których wyniki nie zostały zamieszczone, ponieważ były zbliżone do prezentowanego. Otrzymany rezultat jest niezadowolający. Występują znaczące oscylacje wokół prędkości zadanej i bardzo mocne tętnienia momentu. Między pierwszą, a drugą sekundą symulacji sieć sprawia wrażenie dobrze nauczonej, jednak szybko porzuca swój stan. Na podstawie poczynionych oscylacji stwierdzić można, że proble-

mem jest zanik zdolności do generalizacji. Z powodu dużej stałej uczenia, sieć w każdym kroku dopasowywała się do punktu pracy, co było błędne w kroku następnym. Mając na względzie prostotę obiektu sterowania, można zredukować rozmiar sieci.



Rys. 1. Przebieg prędkości i momentu silnika, regulator SSN 5-3-1
Fig. 1. Motor velocity and torque, controller ANN 5-3-1


Kolejny test przeprowadzony został dla sieci dwuwarstwowej o konfiguracji neuronów 5-1. Wynik przedstawia rys. 2. W porównaniu z rezultatem otrzymanym poprzednio odpowiedź dla przedziału czasowego do pierwszej sekundy symulacji uległa zdecydowanej poprawie. Zniwelowany został efekt niedostatecznej generalizacji zaobserwowany poprzednio. W czasie od pierwszej do drugiej sekundy natomiast nie obserwuje się znaczących różnic, a więc mniejsza sieć zachowuje wystarczającą zdolność kształtowania nieliniowej charakterystyki sterowania, pozwalającą na poprawną regulację. Nie został jednak zniwelowany efekt ciągłego przystosowywania się sieci do aktualnego stanu.



Rys. 2. Przebieg prędkości i momentu silnika, regulator SSN 5-1
Fig. 2. A scope of motor velocity and torque, controller ANN 5-1

Dokładna analiza algorytmu uczenia wskazuje, że sieć uczy się w czasie nawrotu, gdy silnik sterowany jest napięciem znajdującym się w ograniczeniu. Jest to błąd, ponieważ w tym czasie napięcie sterujące jest poprawne, więc mimo znaczącego uchybu prędkości, sieć nie powinna być uczona. W pozycji [3], autorzy zajęli się problemem określenia błędu wykorzystywanego w procesie uczenia sieci, udowadniając, że uchyb regulacji nie jest wyborem najlepszym. Przedstawione zostały różne sposoby, głównie oparte na konstrukcji neuronowych modeli obiektów sterowania i propagacji uchybu regulacji przez model. Wszystkie te zabiegi odnosiły się jednak do obiektów o bardzo złożonej dynamice i są szczególnie skuteczne dla układów wysokich rzę-

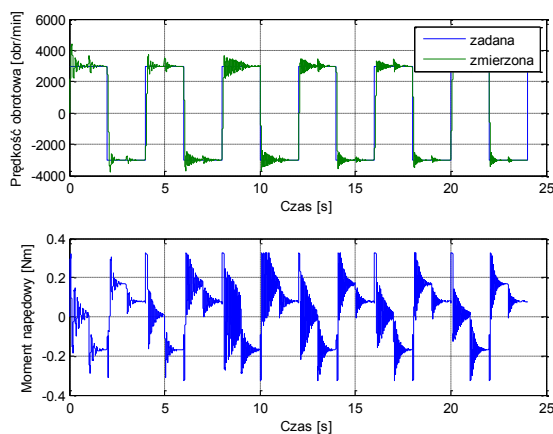
dów lub nieminimalnofazowych. Badanym obiektem jest prosty układ dwóch silników. Nie zachodzi więc tutaj konieczność używania bardzo złożonych obliczeniowo modeli neuronowych, wystarczy jedynie blokować uczenie, kiedy sygnał sterujący jest w ograniczeniu. Wprowadzając tę modyfikację do algorytmu uczenia przeprowadzona została symulacja, której wynik przedstawia rys. 3.



Rys. 3. Przebieg prędkości i momentu silnika, regulator SSN 5-1, blokowanie uczenia

Fig. 3. Motor velocity and torque, controller ANN 5-1, learning blocking

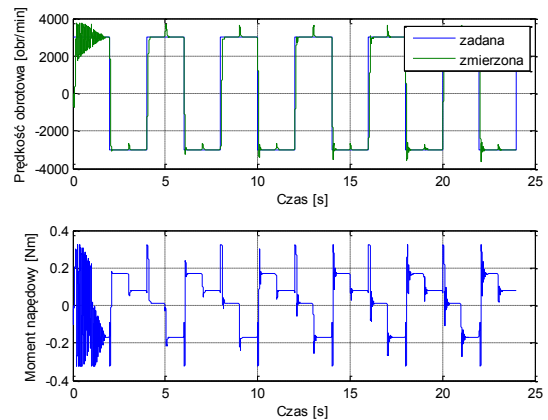
Układ nadal zbyt dynamicznie uczy się w zakresie dużego uchybu (powyżej 100 obr/min) podczas oscylacji. Wprowadzona zostanie więc dodatkowa korekta wartości współczynnika uczenia – ograniczenie jego wartości do $[0; 0,1]$. Uzyskany wynik obrazuje rys. 4. Układ uczy się wyraźnie wolniej, jest jednak mniej wrażliwy na przeuczenie.



Rys. 4. Przebieg prędkości i momentu silnika, regulator SSN 5-1, modyfikacja błędów uczenia

Fig. 4. Motor velocity and torque, controller ANN 5-1, learning error modifying

Poprawa przebiegu procesu regulacji w wyniku zastosowania sposobów modyfikacji błędów uczenia prowadzi do wniosku, że następnym krokiem, jaki należy wprowadzić jest modyfikacja współczynnika uczenia. Należy bowiem skompensować nasycenie błędów w początkowej fazie uczenia, natomiast spowolnić adaptację wag po uzyskaniu poprawnych nastaw. Przebieg uzyskany w wyniku tej modyfikacji pokazuje rys. 5.



Rys. 5. Przebieg prędkości i momentu silnika, regulator SSN 5-1, modyfikacja błędów i stałej uczenia

Fig. 5. Motor velocity and torque, controller ANN 5-1, learning error and factor modifying

Uzyskane przebiegi są bardzo zadowalające, ponieważ osiągnięta została znacząca nieliniowość regulatora. W momencie nawrotu przekształtnik pracuje w ograniczeniu wykorzystując pełną dynamikę obiektu. Skok momentu oporowego natomiast nie wywołuje oscylacji.


3. Analiza wyników

3.1. Analiza wyników symulacyjnych

Przeprowadzono dwa rodzaje badań symulacyjnych dla każdego z regulatorów: rozruchu od postoju do prędkości znamionowej bez obciążenia oraz pracę silnika pod obciążeniem. Oba badania przeprowadzono dla trzech różnych wartości bezwładności obciążenia.

Badania symulacyjne działania regulatora nie mogą być przeprowadzone dla regulatora zaraz po włączeniu. Sieć nie jest wtedy bowiem nauczona i przebiegi nie będą reprezentowały dobrych parametrów. Dlatego badania symulacyjne rozruchu silnika zostaną rozpoczęte z wagami osiągniętymi po nauce, jak na rys. 6. W przypadku badań skoków momentów obciążenia natomiast najpierw przeprowadzona zostanie rozruch trwający dwie sekundy połączony z nauką sieci, podczas których nie będą liczone wskaźniki jakości.

Wyniki badań charakterystyk rozruchowych przedstawiają: rys. 6 oraz tab. 1. Natomiast dla oceny reakcji na skok momentu obciążenia przeanalizować należy rys. 7 oraz tab. 2.




Rys. 6. Charakterystyki rozruchowe

Fig. 6. Startup characteristics

Tab. 1. Wskaźniki jakości charakterystyk rozruchowych
Tab. 1. Quality identifiers of startup characteristics

		Wskaźniki jakości						
		czasowe				całkowe		
		t_n [s]	t_r [s]	e_{max} [obr./min]	$\frac{e_{max}}{y_{zad}} \cdot 100\%$	ISE	ITSE	FM
Bezładność	mała	0,08	0,16	0	0%	$2,21 \cdot 10^5$	3824	13
	średnia	0,26	0,46	180	6%	$8,98 \cdot 10^5$	$6,60 \cdot 10^4$	55
	duża	1,80	2,76	126	4%	$6,04 \cdot 10^6$	$3,01 \cdot 10^6$	352

We wszystkich przypadkach układ zachował się bardzo dobrze. Wystąpiły przeregulowania mniejsze niż 10%, ale nie zaobserwowano oscylacji. Każdy z procesów regulacji był stabilny, nie wystąpiły uchyby ustalone. W fazie narastania prędkości do czasu t_n przekształtnik zasilający silnik pracował w ograniczeniu, co pozwoliło wykorzystać pełną dynamikę układu.



Rys. 7. Charakterystyki zakłóceniewy
Fig. 7. Elimination of disturbance characteristics

Tab. 2. Wskaźniki jakości charakterystyk zakłóceniewy
Tab. 2. Quality identifiers of elimination of disturbance characteristics

		Wskaźniki jakości				
		czasowe		całkowe		
		e_{max} [obr./min]	$\frac{e_{max}}{y_{zad}} \cdot 100\%$	ISE	ITSE	FM
Bezładność	mała	900	90%	$50,30 \cdot 10^4$	$287,14 \cdot 10^4$	75
	średnia	270	27%	$0,88 \cdot 10^4$	$4,93 \cdot 10^4$	110
	duża	180	18%	$1,66 \cdot 10^4$	$9,70 \cdot 10^4$	254

Regulacja w każdym z procesów została przeprowadzona poprawnie, tzn. wystąpiło pojedyncze przeregulowanie, bez oscylacji, a uchyb został zniwelowany do zera. Niestety wystąpiły znaczne przeregulowania (większe niż 10%, a w przypadku układu o małej bezładności nawet 90%), a wskaźniki jakości wyznaczyły duże wartości.

Badania te zostały przeprowadzone w sposób jednakowy ze wszystkimi poprzednimi, tj. dla zadanej prędkości obrotowej wynoszącej jedną trzecią prędkości znamionowej. W publikacji [3] poruszony został zaobserwowany tu problem – a mianowicie sieci neuronowe mają wolniejszą tendencję do uczenia się wokół małych wartości sygnałów wyjściowych i wejściowych.

3.2. Porównanie regulatora neuronowego z klasycznym regulatorem PID

Uzyskane wyniki porównać można z regulatorem klasycznym typu PID. Na potrzeby przedstawionego projektu stworzony i przetestowany został właśnie taki regulator. Wskaźniki jakości uzyskane w analogicznych badaniach przy jego użyciu porównane zostały z dotychczasowymi w tab. 3. Dane liczbowe w tabeli przedstawiają stosunek odpowiednich wskaźników uzyskanych dla badań regulatora neuronowego do jego odpowiednika PID. Mając na uwadze oczekiwanie minimalizacji wszystkich wskaźników jakości wartość mniejsza od jedności wskazuje na lepsze działanie regulatora neuronowego, natomiast większa na regulator PID.

Tab. 3. Stosunek wartości wskaźników jakości uzyskanych przy pomocy regulatora neuronowego do klasycznego PID


Tab. 3. A ratio of quality identifiers scored by the neural controller to the classical PID

		Rozruch					Skok momentu obciążenia		
		t_n	t_r	e_{max}	ITSE	FM	e_{max}	ISE	FM
Bezładność	mała	1,6	1,14	0,00	1,20	0,79	1,50	20,92	0,56
	średnia	0,9	0,77	0,90	0,94	0,95	0,68	0,34	0,80
	duża	0,9	0,86	1,26	0,97	0,99	0,9	0,65	1,20

Wskaźniki czasowe są dla porównywanych regulatorów dość zbliżone, choć stosunek mniejszych od jedności do większych wynosi 11/4. Regulator neuronowy w ogólności wykazywał więc lepszą dynamikę. Wartości wskaźników ITSE i ISE dla układu o małej bezładności są gorsze dla regulatora neuronowego, co wskazuje na nieoptymalne uczenie w ich zakresie. Niemniej jednak dla pozostałych obiektów osiągają one wartości mniejsze od jedności nawet o blisko 70%, co wskazuje na lepsze wykorzystanie dynamiki obiektu przez regulator neuronowy. Najciekawsze wnioski niesie ze sobą analiza wskaźnika FM. W 5 na 6 symulacji osiąga on wartość poniżej 1. Oznacza to, że regulator neuronowy pozwala osiągnąć znaczące oszczędności w zakresie energii potrzebnej do sterowania. Redukcja ta sięgała nawet 44%, co jest wartością bardzo dobrą, gdyż oszczędność ta nie niesie ze sobą pogorszenia dynamiki, a wręcz przeciwnie.

3.3. Porównanie wyników symulacyjnych z wynikami dla obiektu rzeczywistego

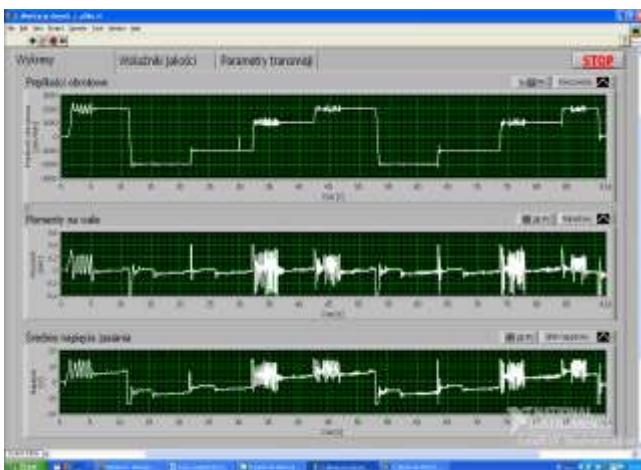
Przeprowadzonych zostało szereg badań na obiekcie rzeczywistym. Miały one na celu skonfrontować symulacyjne wyniki z zachowaniem fizycznego układu. W każdym przypadku regulator był uczony *online*, nie używano nastaw wyznaczonych symulacyjnie, a jedynie wykorzystano te same metody nauki. Przykładowe uzyskane przebiegi przedstawiają rys. 8, rys. 9 i rys. 10.



Rys. 8. Badania na obiekcie rzeczywistym, mała bezwładność
Fig. 8. Experiments on a real object, low inertia



Rys. 9. Badania na obiekcie rzeczywistym, średnia bezwładność
Fig. 9. Experiments on a real object, medium inertia



Rys. 10. Badania na obiekcie rzeczywistym, duża bezwładność
Fig. 10. Experiments on a real object, high inertia

Porównując wyniki badań symulacyjnych z przeprowadzonymi na obiekcie rzeczywistym, można zaobserwować, szczególnie wyraźnie w przypadku parametru e_{max} dla reakcji na skok momentu oporowego, że regulator dla układu rzeczywistego zachowuje się lepiej niż w przypadku badań symulacyjnych. Odpowiedzialna za to jest paradoksalnie obecność szumów pomiarowych. W pracy [5] wtrącanie szumów pomiarowych potraktowane zostało jako metoda generacji danych uczących, prowadząca do osiągnięcia większej zdolności do uogólniania sieci. Takie właśnie zjawisko zachodzi w trakcie pracy regulatora neuronowego.

4. Wnioski

Przeprowadzone badania potwierdziły tezę o wyższości nowoczesnych regulatorów nieliniowych nad klasycznym regulatorem PID. W większości rozpatrywanych wskaźników jakości regulator PID wykazywał się gorszą jakością regulacji. Podobne wyniki uzyskali Autorzy publikacji [1], stosujący regulator PID oraz sztuczną sieć neuronową do sterowania położeniem silnika prądu stałego. Wyższość sztucznej sieci neuronowej nad klasycznym regulatorem typu PI potwierdza także publikacja [2].

Badania symulacyjne, a szczególnie przeprowadzone na obiekcie rzeczywistym pokazują jasno, że na obecnym stanie wiedzy i rozwoju narzędzi analitycznych jesteśmy już w stanie zapanować nad uczeniem maszynowym. Odpowiednio dobrane algorytmy pozwalają na bezpieczną pracę samouczących się regulatorów. W tym zakresie niezbędne są oczywiście dalsze badania pozwalające na uzyskanie niezbędnej pewności w zakresie bezpieczeństwa w celu spełnienia obowiązujących norm. Niemniej jednak kierunek rozwoju przedstawiony w niniejszej pracy okazuje się być słuszny.

Szczególnie ważne i bardzo obiecujące są wyniki analizy wskaźnika zużycia energii elektrycznej. Obecnie często dąży się do minimalizacji zużycia energii. Przedsiębiorcy są skłonni zainwestować większą kwotę na etapie projektowania i budowy licząc na zwrot poniesionych nakładów w czasie eksploatacji. Oszczędność rzędu kilkunastu, czy nawet kilkudziesięciu procent jest zdecydowanie zadowalająca i na pewno w najbliższym czasie właśnie z tego względu nastąpi dynamiczny rozwój metod sterowania opartych na sztucznej inteligencji.

W przypadku sterowania procesami o bardzo złożonej dynamice lub obciążonych bardzo sztywnymi ograniczeniami odnośnie kilku wskaźników jakości jednocześnie, warto więc sięgać po bardziej zaawansowane, niż klasyczny PID, algorytmy regulacji.

5. Literatura

- [1] Comza A., Pitica D.: Artificial Neural Network And PID Based Control System For DC Motor Drives, Optimization of Electrical and Electronic Equipment, 2008.
- [2] Kang Y., Chu M.H., Chang M.W., Chen Y.W., Chen M.C.: The Self-Tuning Neural Speed Regulator Applied to DC Servo Motor, Natural Computation, 2007.
- [3] Korbicz J., Obuchowicz A. i Uciński D.: Sztuczne sieci neuronowe : podstawy i zastosowania, Warszawa: Akademicka Oficyna Wydawnicza PLJ, 1994.
- [4] Liu Z., Zhuang X., Wang S.: Speed Control of a DC Motor Using BP Neural Networks, Control Applications, 2003.
- [5] Tadeusiewicz R.: Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami, Warszawa: Akademicka Oficyna Wydawnicza PLJ, 1998.

otrzymano / received: 19.02.2014

przyjęto do druku / accepted: 02.09.2014

artykuł recenzowany / revised paper