

STABILNOŚĆ UKŁADU STEROWANIA Z REGULATOREM NEURONOWYM

Yuriy HIRNIAK, Orest IVAKHIV, Markiyan NAKONECHNYI, Taras REPETYLO

Lviv Polytechnic National University, Instytut Technologii Komputerowych, Automatyki i Metrologii, ul. Bandery 12, 79013 Lviv, Ukraina
tel.: +38-032-258 21 51 e-mail: oresti@polynet.lviv.ua

Streszczenie: W artykule rozpatrzono sposób syntezy regulatorów neuronowych, które wykorzystuje się do sterowania dynamicznymi obiektami nieliniowymi. Zbadano stabilność układu sterowania z regulatorem neuronowym, którego struktura została zaprojektowana według pożądanej reguły sterowania. Zaproponowano strukturę, w której w przeciwieństwie do zwykle stosowanego wprowadzenia uchybu regulacji na wejście regulatora podaje się sygnał wejściowy oraz wyjściowy na dwa oddzielne wejścia, co powoduje większą skuteczność działania systemu sterowania, a mianowicie polepszenie, jakości sterowania oraz przyspieszenie reakcji systemu na sygnały wymuszające.


Słowa kluczowe: sieć neuronowa, dynamika układu sterowania, system sterowania, stabilność.

1. WPROWADZENIE

Jak wiadomo, obiekty systemów sterowania automatycznego, na przykład, silniki, generatory, piece, obiekty przemysłu chemicznego i petrochemicznego, na ogół są opisywane nieliniowymi równaniami różniczkowymi i tylko przy niewielkich odchyleniach badanej wielkości od wartości zadanej układ może być analizowany, jako układ liniowy. Poza tym, dla większości mechanicznych systemów nie uwzględnia się takich istotnych zjawisk nieliniowych, jak tarcie suche, wpływ luzów i ograniczeń, chociaż przy dokładnym badaniu procesów, jakie zdarzają się w systemach, uwzględnianie nieliniowości cech członów systemu staje się priorytetowym. Obecnie dosyć dogłębnie badane są liniowe obiekty dynamiczne [1] i opracowywane metody ich sterowania.

Matematyczny aparat analizy układów nieliniowych związany jest z badaniem właściwości i rozwiązywaniem nieliniowych równań różniczkowych. Teoria oparta na wykorzystaniu metod numerycznych, odnosi się do określonego rodzaju równań nieliniowych. Zawilość otrzymywania rozwiązań nieliniowych równań różniczkowych spowodowała, że opracowano szereg sprawdzonych metod, pozwalających formułować wnioski, co do charakteru procesów występujących w układzie. Metody te wykorzystują modele uproszczone, uwzględniające właściwości członów nieliniowych i charakter wybranej metody. Do rozwiązywania nieliniowych równań różniczkowych, oprócz analitycznych i graficznych metod, szeroko wykorzystuje się metody modelowania, a także wspomaganie komputerowe w rozwiązywaniu problemów sterowania. Aparat teorii sieci neuronowych [2 - 4] pozwala uwzględnić nieliniowości,

realizując pewne funkcjonalne odwzorowania za pomocą superpozycji od linearnej kombinacji funkcji aktywacji. Przykładem obiektu nieliniowego może być napęd elektryczny ręki robota, którego elementem wykonawczym jest silnik prądu stałego ze sterowaniem w obwodzie twornika. Położenie ręki robota jest określone poprzez kąt obrotu wału wyjściowego silnika, do którego jest ona podłączona za pomocą przekładni zębatej, albo ślimakowej. W tym wypadku do momentu bezwładności wirnika trzeba dodać moment bezwładności ręki robota, a do momentu działającej siły - moment sił oporności, jakie działają na rękę robota. Przy układaniu równań dynamiki obiektu sterowania należy wprowadzić komponenty, które uwzględniają masę ręki i działanie odpowiednich sił. Należy także uwzględnić, że silnik jest obciążony momentem tarcia lepkiego i moment ten zależy od kąta skrętu ręki robota. Równanie silnika ze wzbudzeniem obcym i określonymi momentami jest nieliniowym równaniem różniczkowym drugiego rzędu. Linearyzacja otrzymanego równania powoduje jego duże uproszczenie, ale nie uwzględnia się wówczas czynnika wpływającego w istotny sposób na zalanie silnika w stanach przejściowych i ustalonych. Toteż do systemu automatycznego regulowania ręką robota, jako obiektu nieliniowego, wprowadzono regulator neuronowy (rys. 1), który poprawia sterowanie systemem.



Rys. 1. Schemat wprowadzenia regulatora neuronowego do systemu sterowania automatycznego

Posługując się nieliniowym równaniem różniczkowym, którym opisuje się obiekt sterowania, można jednoznacznie zdefiniować taką konfigurację wejść dynamicznej sieci neuronowej, aby zabezpieczyła ona odtwarzanie procesu, odpowiadającego rozwiązywaniu tego równania. Struktura dynamicznej sieci neuronowej dla odtwarzania liniowego równania różniczkowego jest określana poprzez wprowadzenie transformaty Z do rozważanego równania, a nieliniowe zależności, wchodzące w strukturę nieliniowego

równania różniczkowego są uwzględniane przez wprowadzenie członów z nieliniowymi funkcjami aktywacji między wejściami i wyjściami warstw ukrytych neuronowej sieci dynamicznej [5].

2. PROJEKTOWANIE STRUKTURY REGULATORA

Z eksperymentalnych badań dynamiki ręki robota, działającego w jednym z sześciu możliwych kierunków, wynika równanie nieliniowe drugiego rzędu ze składnikiem o charakterze sinusoidalnym [6]:

$$\frac{d^2 y}{dt^2} + 2 \frac{dy}{dt} + 10 \sin y = u(t); \quad (1)$$

gdzie: y - odpowiedź obiektu sterowania na wejściowy sygnał sterowania u , przy czym związek sygnału sterującego obiektem, a jego wyjściem w stanie ustalonym opisuje zależność:

$$y = \frac{1}{10} \arcsin u. \quad (2)$$

Uważa się, iż dynamiczna sieć neuronowa powinna pełnić funkcje regulatora typu PID [1], ponieważ sygnał sterowania uwzględnia zarówno bieżącą zmianę wielkości regulowanej obiektu sterowania (składnik P) jak i jej prognozowaną poprzez szybkość zmian wartość (składnik D), oraz poprzedni stan (składnik I). Równanie regulatora opisuje się wzorem:

$$u(t) = K_q \frac{d\Delta y(t)}{dt} + K_n \Delta y(t) + K_i \int_0^{T_i} \Delta y(t) dt, \quad (3)$$

gdzie: $u(t)$ - wyjściowy sygnał regulatora; $\Delta y(t)$ - różnicowy sygnał na wejściu regulatora (Δy_k - jego postać dyskretna, rys. 2); T_i - okres całkowania; K_q , K_n , K_i - współczynniki odpowiednio przy różniczkowej, bieżącej oraz całkowanej składowej sygnału sterowania.

Przekształcenie Laplace'a równania (3) przyjmuje postać:

$$U(s) = \left(K_q s + K_n + \frac{K_i}{s} \right) Y(s). \quad (4)$$

Transmitancja regulatora:

$$W(s) = U(s)/Y(s) = K_q s + K_n + K_i/s. \quad (5)$$

Dynamiczna sieć neuronowa funkcjonuje, jako dyskretny układ, dlatego algorytm PID należy przedstawić ją w postaci dyskretniej:

$$\begin{aligned} W(z) &= K_q (1-z^{-1})/\Delta t + K_n + (K_i \Delta t)/(1-z^{-1}) = \\ &= \frac{1}{(1-z^{-1})} \left[\frac{K_q}{\Delta t} (1-z^{-1})^2 + K_n (1-z^{-1}) + K_i \Delta t \right] = \\ &= \frac{1}{(1-z^{-1})} \left[\left(\frac{K_q}{\Delta t} + K_n + K_i \Delta t \right) - \left(2 \frac{K_q}{\Delta t} + K_n \right) z^{-1} + \frac{K_q}{\Delta t} z^{-2} \right] = \\ &= \frac{w_{11} + w_{12} z^{-1} + w_{13} z^{-2}}{1 - w_{14} z^{-1}}, \end{aligned} \quad (6)$$

gdzie: wykorzystano przekształcenie $s = (1-z^{-1})/(\Delta t)$ oraz wprowadzono następujące oznaczenia $w_{13} = K_q/\Delta t$; $w_{11} = (K_q + K_n \Delta t + K_i \Delta t^2)/\Delta t$; $w_{12} = -(2K_q + K_n \Delta t)/\Delta t$; $w_{14} = 1$ - współczynniki wagowe dobrane przy uczeniu; Δt - okres dyskretyzacji.


Współczynniki wagowe sieci neuronowej są powiązane ze współczynnikami równania regulatora zależnościami: $K_n = -(w_{12} + 2w_{13})$;

$$K_i = (w_{11} + w_{12} + w_{13})/\Delta t; \quad K_q = w_{13} \Delta t.$$

Równanie różniczkowe, odpowiadające zależności (5), na k -tym kroku sterowania będzie mieć postać:

$$u_k = w_{11} \Delta y_k + w_{12} \Delta y_{k-1} + w_{13} \Delta y_{k-2} + w_{14} u_{k-1}. \quad (7)$$

Równanie (7) określa strukturę jednowarstwową czterowejściowej sieci neuronowej z jednym sumatorem i jednym liniowym schematem aktywacji (rys. 2).



Rys. 2. Schemat PID-regulatora neuronowego

Wejściowe sygnały sumatora tworzy się za pomocą czterech składników z odpowiednimi współczynnikami wagowymi w_{11} , w_{12} , w_{13} i w_{14} oraz trzech linii opóźniających [7].

3. METODY STROJENIA REGULATORÓW NEURONOWYCH

Do uczenia sieci neuronowej celowe jest wykorzystywanie bardzo wydajnych algorytmów gradientowych. Wyznaczanie gradientu należy prowadzić metodą propagacji wstecznej, którą można prosto zrealizować programowo za pomocą macryz akcji tego samego typu. Wśród algorytmów uczenia sieci neuronowych najbardziej wydajnym jest algorytm Levenberga-Marquardta [4]. Otrzymane równania do obliczania gradientów funkcjonu błędu, z regulowanymi parametrami dla wyjściowej i pośrednich warstw wielowarstwowej sieci neuronowej, pozwalają na korygowanie współczynników wagowych sieci, czym zapewnia się minimalizację odchylenia jej sygnałów wyjściowych od wartości zadanych. Przy tym należy znać sygnały wejściowe i wyjściowe: sygnał na wejściu regulatora neuronowego (ciąg r_k); sygnał na wyjściu obiektu (ciąg y_k); wyjściowy sygnał regulatora neuronowego (ciąg u_k , podawany na wejście obiektu). Przy uczeniu (rys. 1) regulatora neuronowego z wybraną architekturą, współczynniki wagowe sieci definiuje się za pośrednictwem wzorca [7]. Na etapie uczenia sieci wartości

współczynników wagowych regulatora neuronowego dobiera się tak, aby zabezpieczyć zbieżność sygnałów wyjściowych wzorca i obiektu sterowania z pożądaną wartością błędu rozbieżności.

Na początku procedury uczenia wszystkie trzy wymienione ciągi są niewiadome. Jeśli kierować się wejściowym sygnałem (ciąg r_k), wtedy na mocy matematycznego modelu wzorca można znaleźć ciąg y_k , ale wówczas niewiadomym pozostaje ciąg u_k (przypuszczamy również, że $y_k = y_{rk}$). Jeśli natomiast uważać ciąg u_k za znany i podać jego na wejście obiektu, wtedy na jego wyjściu otrzymamy ciąg y_k , jednak przy tym niewiadomym pozostanie ciąg r_k .

Matematycznym modelem wzorca jest liniowe równanie różnicowe, dobrane z uwzględnieniem szeregu warunków, a mianowicie:


- rząd stopnia równania różniczkowego powinien zbiegać się z rzędem równania dynamiki obiektu sterowania (w tym przypadku – drugiego);
- wartości stałych współczynników dobierane są z warunku zapewnienia zbieżności sygnałów, odpowiednio, wejściowego r i wyjściowego y_r wzorca i obiektu w stanie ustalonym;
- wartości stałych współczynników przy pierwszej pochodnej i członie swobodnym dobierane są z warunku zapewnienia pożądanego początku procesu przejściowego.

Możliwości poprawienia szybkości reagowania zostały zbadane przy uczeniu sieci z wykorzystaniem modeli z odmiennymi początkami procesu przejściowego - stromym (przyśpieszony wzorec), łagodnym (spowolniony wzorec), które zostały określone przez współczynniki przy pierwszej pochodnej (szybkość zmiany wyjściowego sygnału) i członie swobodnym w równaniu dynamiki wzorca. Przy czym duże wartości współczynników wybiera się dla przyśpieszonego wzorca, a małe dla spowolnionego wzorca. Z przeprowadzonej analizy wynika równanie:

$$\frac{d^2 y_r}{dt^2} + 6 \frac{dy_r}{dt} + 9 y_r = 9 r, \quad (8)$$

gdzie: r oraz y_r - odpowiednio wejściowy oraz wyjściowy sygnał wzorca i obiektu.

Porównanie (rys. 3) wyjściowych sygnałów wzorca oraz obiektu (otrzymujemy sygnał rozbieżności Δy_k) wskazuje [8] na niską efektywność systemu sterowania z wykorzystaniem regulatora neuronowego, nastrojonego według wzoru (7).




Rys. 3. Porównanie względne przebiegu procesu przejściowego sygnałów wyjściowych wzorca y_r oraz obiektu y (dla schematu na rys. 2)

Dla uzyskania wymaganych dynamicznych charakterystyk procesu sterowania udoskonalono architekturę regulatora [8]; zamiast wprowadzenia na wejście regulatora wartości uchybu regulacji Δy_k oraz jego poprzednich (opóźnionych) wartości Δy_{k-1} , Δy_{k-2} zaproponowano wykorzystanie dwóch oddzielnych wejść. Na jedno z nich wprowadzono wartości sygnałów wejściowych r_k , r_{k-1} , r_{k-2} , a na drugie - sygnałów wyjściowych y_k , y_{k-1} , y_{k-2} , każdy ze swoimi współczynnikami wagowymi ustalonymi osobno przy uczeniu sieci neuronowej.

Działanie regulatora neuronowego z rozdzielonymi wejściami (rys. 4) opisuje wyrażenie:


$$u_k = w_{11} r_k + w_{12} r_{k-1} + w_{13} r_{k-2} + w_{14} y_k + w_{15} y_{k-1} + w_{16} y_{k-2} + w_{17} u_{k-1} \quad (9)$$

Przy $w_{14} = -w_{11}$, $w_{15} = -w_{12}$, $w_{16} = -w_{13}$ działanie regulatora będzie ekwiwalentne do poprzedniej struktury (rys. 2), ale w procesie uczenia współczynniki w przypadku oddzielnych wejść dobiera się niezależnie, co pozwala podawać sygnał sterowania na obiekt poza wpływem sprzężenia zwrotnego. Wartość współczynnika wagowego w_{17} przyjęto, jako stałą i równą 1.



Rys. 4. Schemat regulatora neuronowego z rozdzielonymi wejściami w rodzaju jednej sieci

Z porównania (rys. 5) wyjściowych sygnałów wzorca i obiektu sterowanego takim regulatorem wynika, że w tym wypadku system ma znacznie lepsze właściwości dynamiczne w porównaniu z poprzednią strukturą (z tradycyjnym wprowadzeniem uchybu regulacji), co potwierdza celowość wykorzystywania regulatora z rozdzielonymi wejściami [8].



Rys. 5. Porównanie względne przebiegu procesu przejściowego sygnałów wyjściowych wzorca y_r oraz obiektu y (dla schematu na rys. 4)

4. BADANIE STABILNOŚCI UKŁADU STEROWANIA

W celu zbadania stabilności struktury układu z regulatorem neuronowym należy dokonać przekształcenia w taki sposób, aby otrzymać równoważny układ ze sprzężeniem zwrotnym. W tym celu z równania (9) wyodrębniono pętlę sprzężenia zwrotnego ($\Delta y_k = r_k - y_k$). Dopełniając równanie (9) wyrazem:

$$0 = w_{14}r_k + w_{15}r_{k-1} + w_{16}r_{k-2} - w_{14}r_k - w_{15}r_{k-1} - w_{16}r_{k-2}, \quad (10)$$

oraz grupując składniki przy uwzględnieniu, że $\Delta y_k = r_k - y_k$, otrzymujemy:

$$u_k = (w_{11} + w_{14})r_k + (w_{12} + w_{15})r_{k-1} + (w_{13} + w_{16})r_{k-2} - w_{14}\Delta y_k - w_{15}\Delta y_{k-1} - w_{16}\Delta y_{k-2} + w_{17}u_{k-1}. \quad (11)$$

Jeżeli przyjmiemy $u_k = u_{1,k} + u_{2,k}$, to równanie (11) przyjmie postać:

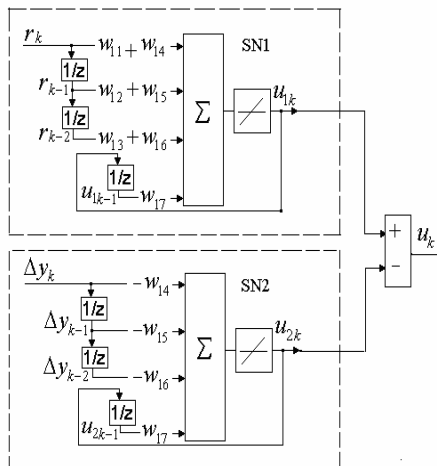
$$u_{2,k} = -w_{14}\Delta y_k - w_{15}\Delta y_{k-1} - w_{16}\Delta y_{k-2} + w_{17}u_{2,k-1}, \quad (12)$$

oraz

$$u_{1,k} = (w_{11} + w_{14})r_k + (w_{12} + w_{15})r_{k-1} + (w_{13} + w_{16})r_{k-2} + w_{17}u_{1,k-1}. \quad (13)$$

Dzięki podobnej funkcjonalnej schematów regulatorów neuronowych, opisywanych przez wyrazy (9) oraz (11) - (13), można badać funkcjonowanie systemu, w którym regulator neuronowy będzie składać się z dwu równoległych sieci (rys. 6).

W takim systemie sterowanie procesem jest zrealizowane z wykorzystaniem wyjściowych sygnałów dwu sieci neuronowych o jednakowej strukturze, przy czym ich sygnały wyjściowe dodają się i sumaryczny sygnał jest podawany na wejście obiektu sterowania. Wartość sygnału na wyjściu pierwszej sieci neuronowej (SN1) jest zależna wyłącznie od sygnału sterowania i nie zależy od wartości wielkości regulowanej. Natomiast wyjście drugiej sieci neuronowej (SN2) formuje się na podstawie sygnału uchybu regulacji, podawanego w torze sprzężenia zwrotnego na drugie wejście sumatora.



Rys.6. Struktura regulatora neuronowego z rozdzielonymi wejściami w rodzaju dwu identycznych sieci

Transmitancje dyskretne obydwu sieci neuronowych mają postać:

$$W_1(z) = \frac{U_1(z)}{r(z)} = \frac{(w_{11} + w_{14}) + (w_{12} + w_{15})z^{-1} + (w_{13} + w_{16})z^{-2}}{1 - w_{17}z^{-1}}, \quad (14)$$

$$W_2(z) = \frac{U_2(z)}{\Delta y_k(z)} = \frac{-w_{14} - w_{15}z^{-1} - w_{16}z^{-2}}{1 - w_{17}z^{-1}}. \quad (15)$$

Dla badania stabilności układu utworzony system przeanalizujemy, jako ciągły, czyli przejdziemy od dyskretnej formy przedstawienia funkcji przejścia do ciągłej, wykorzystując związek $z = 1/[1 - s(\Delta t)]$ pomiędzy liczbami z i s . Funkcje przejścia w przestrzeni s dla sieci neuronowych SN1 i SN2 przyjmą postać:

$$W_1(s) = K_{g1}s + K_{n1} + \frac{K_{i1}}{s}; \quad (16)$$

$$W_2(s) = K_{g2}s + K_{n2} + \frac{K_{i2}}{s}. \quad (17)$$

Strukturalny schemat systemu sterowania automatycznego z wykorzystaniem ekwiwalentów ciągłych sieci neuronowych jest analogiczny do poprzedniego, z tym, że zamiast transmitancji dyskretnych obwodów (14) - (15) mamy ich odpowiedniki ciągłe (16)-(17). W tym systemie można wyodrębnić dwie główne części: pierwszą, jako obwód z transmitancją $W_1(s)$, za pośrednictwem, której sygnał r przekształca się w pierwszą część sygnału sterowania U_1 i drugą, jako obwód, szeregowo połączonych elementów z transmitancjami $W_2(s)$ i $W_0(s)$ objęty sprzężeniem zwrotnym, za pomocą, których, na podstawie informacji o sygnale błędu rozbieżności Δy (Δy_k - jego postać dyskretna), formuje się drugą część sygnału sterowania U_2 . Transmitancja takiego układu, objętego sprzężeniem zwrotnym przyjmuje postać:

$$W(s) = \frac{Y(s)}{R(s)} = \frac{W_0(s)(W_1(s) + W_2(s))}{1 + W_0(s)W_2(s)} = \frac{(K_{g1} + K_{g2})s^2 + (K_{n1} + K_{n2})s + K_{i1} + K_{i2}}{s^3 + (K_{g2} + 2)s^2 + (K_{n2} + 10)s + K_{i2}}. \quad (18)$$

Taka postać regulatora neuronowego umożliwia analizowanie utworzonego systemu, jako układu ciągłego. Należy zbadać mianownik transmitancji układu zamkniętego:

$$F(s) = 1 + W_0(s)W_2(s) = s^3 + (K_{g2} + 2)s^2 + (K_{n2} + 10)s + K_{i2}. \quad (19)$$

Stabilność systemu zostanie utrzymana, gdy wszystkie pierwiastki równania charakterystycznego (biegunów funkcji przejścia) będą miały ujemne części rzeczywiste. Dla równania charakterystycznego w ogólnej postaci

$$a_3s^3 + a_2s^2 + a_1s + a_0 = 0, \quad (20)$$

według algorytmu Hurwitza [1] system jest stabilny, jeśli spełnione są warunki:

$$a_3 > 0; a_2 > 0; c_{1,3} = a_1 - (a_3 a_0) / a_2 > 0; c_{1,4} = a_0 > 0. \quad (21)$$

W naszym przypadku dla zabezpieczenia stabilności układu zamkniętego niezbędne jest spełnienie warunków:

$$a_3 = 1 > 0; a_2 = (k_{g2} + 2) > 0;$$

$$c_{1,3} = k_{n2} + 10 - (1 \cdot k_{i2}) / (k_{g2} + 2) = k_{n2} + 10 - k_{i2} / (k_{g2} + 2) > 0;$$

$$c_{1,4} = k_{i2} > 0. \quad (22)$$

Badania symulacyjne w środowisku Simulink [6] potwierdziły możliwość zabezpieczenia stabilności systemu z podaną konfiguracją regulatora.

5. WNIOSKI KOŃCOWE

1. W celu otrzymania potrzebnych dynamicznych charakterystyk systemu sterowania z wykorzystaniem sieci neuronowej docelowo należy przeprowadzić uczenie systemu, jako układu otwartego, a sprzężenie zwrotne realizować po zakończeniu procedury nauczania.

2. W wypadku wykorzystania proporcjonalno-całkowozróżnicowanej reguły sterowania regulator neuronowy można zbudować na jednym czterowejściowym neuronie z liniową funkcją aktywacji, umieszczając przed jego wejściami dwie linie opóźnienia sygnałów wejściowych regulatora oraz jedną linię opóźnienia dla sygnału wyjściowego neurona, który podaje się na jego odpowiednie wejście obwodem sprzężenia zwrotnego. Przy czym dla uczenia regulatora neuronowego potrzebna jest wiedza o znaczeniu sygnałów na wejściach i wyjściach wzorca i obiektu fizycznego, czyli jego modelu matematycznego.

3. Poprawniejsze charakterystyki dynamiczne można otrzymać, wykorzystując regulator z rozdzielonymi wejściami.

4. Dla sprawdzania stabilności układu sterowania z regulatorem neuronowym należy przekształcić jego strukturę w równoważną mu strukturę formując podsystem z ujemnym sprzężeniem zwrotnym.

5. BIBLIOGRAFIA

1. Goodwin F.C., Fraebe S.F., Salgado M.E.: Control System Design. Prentice Hall, Upper Saddle River, New Jersey, 2001.
2. Norgaard M., Ravn O., Poulsen N., Hansen I.: Neural Networks for Modelling and Control of Dynamic Systems. Springer, London, 2000.
3. Rutkowska D., Piliński M., Rutkowski L.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. Wydawnictwo naukowe PWN, Warszawa, 2004.
4. Osowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna wydawnicza politechniki Warszawskiej, Warszawa, 2000.
5. Flasiński M.: Wstęp do sztucznej inteligencji, Warszawa 2011.
6. Neural Network Toolbox Documentation [Online] The MathWorks, inc. available: <http://www.mathworks.com/help/nnet/index.html>
7. Ivakhiv O., Nakonechnyi M., Nakonechnyi Yu., Stadnyk B.: Neural Controllers with Different Teaching Sequences Configurations Creation./ Folia Scientiarum Universitatis Technicae Rosouiensis, NR 233, 2006, p. 153 – 163.
8. Hirnyak Yu., Ivakhiv O., Nakonechnyi M., Repetylo T.: Control System of Robot Movement, IDAACS'2013, The 7 IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems (IDAACS), Volume 1, September 12-14, 2013, Berlin, Germany, p. 334-337.

STABILITY OF SYSTEM WITH NEUROCONTROLLER

The nature of nonlinearities in the objects of control particularly in the drives of robotic systems as dynamic objects of the second order is analyzed and shown that under the influence of some loads the mathematical model of such object is nonlinear and its linearization leads to disregard factors that significantly affect the dynamics of the object. The controllers which are built using classical methods in the process of system operation do not provide full adequacy between the values of specified and actual controlled variables of nonlinear control objects. An application of neural controllers promises the best prospects. We consider features of construction of dynamic neural network and the mathematical models of standard carried the review of functions of activation neurons and feasibility of using gradient algorithms including the algorithm Levenberg - Marquardt for training dynamic neural networks.

It is supposed that the system is based on the proportional-integral-differential law. The stability of the system supported by neurocontroller with two separated inputs is discussed. Obviously the control action of such dynamic system is corresponded with the difference between output signals of the non-linear object and the chosen standard. On contrary to a typical structure it was proposed to put these signals on two separate inputs. During the training procedure everyone weight is found one from another independently. This task has been considered which include the location of the dominant roots of the characteristic equation of the closed-loop system in a given area of the complex plane of the roots and then return back to the open-loop system. The comparison of obtained errors in traditional and proposed structures of neurocontroller showed that the last one is the most effective in quality and productivity sense.

Keywords: neuron, network, non-linear, object, system, control, controller, algorithm, studying.