

Marcin LIS*
Piotr KOZIERSKI*

WPLYW DODANIA MAŁEJ SIECI NEURONOWEJ DO REGULATORA PID NA JAKOŚĆ REGULACJI

W artykule podjęto próbę implementacji połączenia regulatora PID oraz małej sieci neuronowej, zbadano wpływ takiego połączenia na jakość regulacji. Obiektem badanym jest przetwornica typu Buck sterowana prądem. Głównym kryterium badania było dobranie sieci pod kątem ograniczenia zasobów systemu sterowania. Porównano sieci o jednym, dwóch oraz trzech neuronach w warstwie ukrytej dla różnych punktów pracy przetwornicy.

1. WPROWADZENIE

Regulator PID jest jednym z najpowszechniej używanych regulatorów w przemyśle w pętli sprzężenia zwrotnego. Szacuje się, że ponad 95 % układów sterujących to właśnie takie regulatory [1]. Dzieje się tak dzięki ich prostocie w implementacji do zadań niewymagających optymalnej kontroli.

Regulator PID ma jednak dość ważną wadę – na skutek starzenia się obiektu, zmiany jego parametrów czy zmiany punktu pracy, pogarsza się jakość sterowania. Tak więc operator ma trzy możliwości: zgodzić się na gorsze warunki sterowania obiektem (jeżeli są w akceptowalnych granicach), dostroić regulator we własnym zakresie lub skorzystać z regulatora o bardziej rozbudowanej strukturze i możliwościach adaptacji. Literatura bogata jest w opracowania adaptacyjnych regulatorów PID np. [4] [5].

W dzisiejszych czasach coraz większą uwagę przykładają się do heurystycznych metod sterowania. Mając niepełne dane o obiekcie, metody takie pozwalają na generowanie sygnału sterującego, który w porównaniu do regulatora PID ma lepsze osiągi co do wskaźników jakości. Jedną z metod heurystycznych jest zastosowanie sieci neuronowej.


Sieć neuronowa może pełnić rolę sterownika sama w sobie [6] (*neurocontroller*, *neurodriver*), naśladować strukturę regulatora PID [3], nadzorować zmianę parametrów regulatora PID według określonych kryteriów [7], itp. W publikacji wybrano opcję rozbudowy regulatora o człon sztucznej sieci neuronowej.

* Politechnika Poznańska.

2. OBIEKT STEROWANIA

Obiektem sterowania jest przetwornica typu Buck, przedstawiona na rys. 1. Przetwornica pracuje na obciążeniu mocno indukcyjnym. Parametry przetwornicy:

- $L = 2.5 \text{ mH}$,
- $U_{\text{in}} = 100 \text{ Vdc}$,
- $R_{\text{obc}} = 1 \Omega$,
- $f_{\text{switch}} = 12.5 \text{ kHz}$.



Rys. 1. Przetwornica typu Buck zaimplementowana w programie Simulink

Z punktu widzenia sterowania należy przyjąć, iż przekształtnik jest obiektem dyskretnym ze względu na tranzystor. Wszystkie symulacje były przeprowadzone w programie Simulink z użyciem SimPowerSystems Toolbox z krokiem symulacyjnym równym $0.1 \mu\text{s}$. Tak mały krok pozwala dokładniej zamodelować zjawiska występujące przy przełączaniu tranzystora oraz indukcyjności.

Jedynym dostępnym sygnałem z układu jest informacja o prądzie płynącym przez obciążenie. Sygnałem sterującym obiekt jest sygnał PWM, który powstaje poprzez modulację sygnału przychodzącego z regulatora PID.

Zadanie sterowania polega na nadążaniu prądu obciążenia za sygnałem:

$$r(t) = 5 \cdot \sin(2 \cdot \pi \cdot 50) + \frac{5}{17} \cdot \sin(2 \cdot \pi \cdot \frac{50}{17}) + b \quad (1)$$

gdzie: b jest stałą dla danej symulacji, przyjmuje wartości ze zbioru $\{20, 50, 80\}$.

3. REGULATOR

3.1. Regulator PID

Klasyczna implementacja regulatora PID może być opisana równaniem:

$$u(t) = K_p \cdot e(t) + K_i \cdot \int e(t) dt + K_d \cdot \frac{d}{dt} e(t) \quad (2)$$

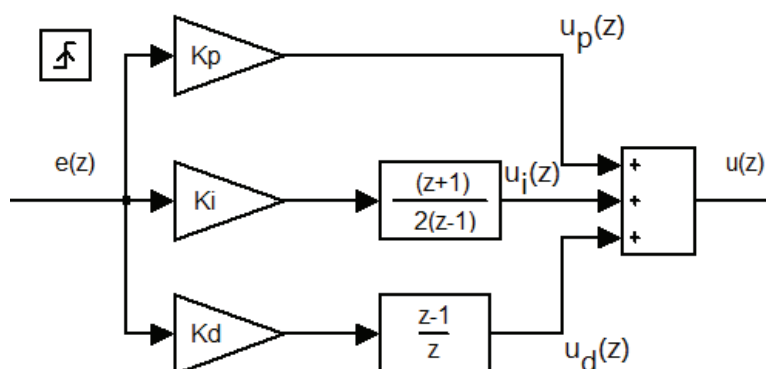
gdzie: K_p , K_i oraz K_d są parametrami regulatora, $e(t)$ oznacza uchyb ($e(t) = r(t) - y(t)$), a $u(t)$ sygnał sterujący obiektem.

Ograniczenia, jakie narzuca obiekt na sterowanie związane jest z tranzystorem, nie można zmieniać wartości sygnału sterującego częściej, niż raz na okres załączania. Gdyby było to możliwe, oznaczałoby to zmienną częstotliwość załączania tranzystora, a to nie jest dozwolone. Z tego powodu zachodzi potrzeba zaimplementowania dyskretnego regulatora PID. Taki regulator można opisać wzorem (w dziedzinie zmiennej zespolonej z):

$$u(z) = e(z) \cdot \left(K_p + K_i \cdot \frac{T_p}{2} \cdot \frac{z+1}{z-1} + K_d \cdot \frac{z-1}{T_p \cdot z} \right) \quad (3)$$

gdzie: T_p oznacza czas próbkowania, zgodny z częstotliwością załączeń tranzystora ($T_p = f_{switch}^{-1}$).

Implementacja dyskretnego regulatora PID w Simulinku została przedstawiona na rys. 2. Odpowiednie zachowanie się regulatora uzyskano poprzez umieszczenie go w bloku *subsystem* z opcją zewnętrznego *triggera*, który jest aktywowany na zbocze narastające sygnału PWM. Składowe sygnały sterującego $u(z)$ służą jako sygnały wejściowe do sieci neuronowej.



Rys. 2. Implementacja dyskretnego regulatora PID w programie Simulink

3.2. Sieć neuronowa

Aby rozwinąć możliwości regulatora dodano część neuronową. Sieć neuronowa jest dla warstwy ukrytej typu feedforward, a dla warstwy wyjściowej rekurencyjna (jedno sprzężenie od wyjścia do wejścia neuronu). W warstwie wyjściowej zawsze znajduje się jeden neuron z funkcją aktywacji tansig, w warstwie ukrytej w zależności od eksperymentu, pomiędzy 1 a 3 neurony z funkcją aktywacji logsig. Sieć posiada 6 sygnałów wejściowych. Działanie tak powstałego regulatora można opisać wzorem:

$$u(z) = e(z) \cdot \left(K_p + K_i \cdot \frac{T_p}{2} \cdot \frac{z+1}{z-1} + K_d \cdot \frac{z-1}{T_p \cdot z} \right) + f \left(u_p(z), \frac{u_p(z)}{z}, u_i(z), \frac{u_i(z)}{z}, u_d(z), \frac{u_d(z)}{z} \right) \quad (4)$$

gdzie: $f(\bullet)$ oznacza wartość wyjścia z sieci neuronowej, liczonej ze składowych sygnału $u(t)$ dla zwykłego regulatora PID oraz składowych sygnału $u(t)$ opóźnionego o jeden okres próbkowania.

Każda sieć neuronowa składa się z wag, które przy inicjalizacji sieci są losowane z przedziału $(-1, 1)$. Przez pierwszy półokres sygnału sterującego ($b = 50$) sieci poddawane są adaptacji metodą Adaptacyjnych Interakcji [2], do porównania brane są już nauczone sieci. Po pierwszym półokresie sygnału sterującego proces adaptacji jest zatrzymywany i wagi się nie zmieniają.

4. WYNIKI SYMULACYJNE

Do porównania wyników pomiędzy regulatorem PID a jego rozwinięciem z użyciem sieci neuronowej użyto wskaźnika jakości o wzorze:

$$J = \frac{1}{N} \sum_{n=1}^N (r_n - y_n)^2 \quad (5)$$

gdzie: N – liczba próbek symulacji, r_n – sygnał referencyjny w n -tej chwili symulacji, y_n – sygnał wyjściowy z obiektu w n -tej chwili symulacji.


Dla wszystkich przeprowadzonych symulacji regulator PID posiadał takie same nastawy. Sieci neuronowe pogrupowano według ilości neuronów w warstwie ukrytej. Zestaw oznacza pewien niepowtarzalny zbiór wylosowanych i wyewoluowanych wag, które nie zmieniają się podczas eksperymentu. Rekurencja w warstwie wyjściowej jest zaimplementowana w postaci podania na wejście neuronu w warstwie wyjściowej jego wyjścia w chwili poprzedniej przemnożonej przez współczynnik -0.3 . Operacja rekurencji jest realizowana 5 razy. Bez neuronu rekurencyjnego w warstwie wyjściowej wszystkie wyniki zmieniają się w granicach 10 %. Sygnał prądowy podawany na regulatory jest uśredniany za okres T_p .

W tabeli 1 przedstawiono najlepsze wyniki otrzymane z serii 100 prób. Dla żadnej z analizowanych sieci nie udało się znaleźć takiej, która miała by lepszy wskaźnik jakości w porównaniu do samego regulatora PID dla rozważanych zakresów sterowań. Zauważono jednak pewną zależność. Mimo tego, że sieć była uczona przez półokres sinusoidy dla $b = 50$, układ regulatora z siecią w przeważającej większości wykazywał lepsze działanie raz dla $b > 50$, a raz dla $b < 50$. Nie pojawiła się sytuacja, w której sieć neuronowa polepszyła wyniki regulatora w całym zakresie sygnału sterującego.

Tabela. 1. Porównanie wskaźnika J dla różnych sieci neuronowych i regulatora PID

Liczba neuronów w warstwie ukrytej	Wartość wskaźnika J		
	b = 20	b = 50	b = 80
0 (sam PID)	0.3943	0.0502	0.5314
1 (zestaw 1)	0.1547	0.1345	0.7090
1 (zestaw 2)	0.5923	0.0924	0.1804
1 (zestaw 3)	0.4941	0.0634	0.2914
2 (zestaw 1)	0.2244	0.1517	1.2286
2 (zestaw 2)	0.4187	0.0553	0.4859
2 (zestaw 3)	0.2409	0.1238	0.4177
2 (zestaw 4)	0.4711	0.0368	0.3765
3 (zestaw 1)	0.1545	0.1474	0.7318
3 (zestaw 2)	0.7536	0.0737	0.2900
3 (zestaw 3)	0.2547	0.0717	0.7099

Można zauważyć, że istnieją obszary, w których regulator PID steruje lepiej bez dodatkowego sygnału pochodzącego z sieci neuronowej, ale są również i takie, w których sieć poprawia znacząco wskaźnik jakości. Na rys. 3 przedstawiono wyniki symulacyjne wartości wskaźnika J od wartości b dla samego regulatora PID oraz regulatora PID z dodaną siecią o 1 neuronie w warstwie ukrytej (zestaw 1 oraz zestaw 2).



Rys. 3. Zależność wartości wskaźnika J parametru b dla regulatora PID oraz PID z siecią neuronową

Zwiększenie ilości neuronów w warstwie ukrytej nie wpływa na wielkość wskaźnika J w sposób, jaki można było tego oczekiwać. Sieci takie z założenia powinny mieć większe możliwości obliczeniowe. W przeprowadzonej próbie stwierdzono, że nie opłaca się poświęcać dodatkowego czasu obliczeniowego na praktycznie minimalną poprawę wskaźnika J .

Dla najbardziej optymalnego sterowania wydawać by się mogło, że należy w zależności od punktu pracy stosować (przełączając się pomiędzy strukturami):

- do około 35 A regulator PID + 1 neuron w warstwie ukrytej z zestawu 1,
- od około 35 A do około 55 A sam regulator PID,
- powyżej 55 A regulator PID + 1 neuron w warstwie ukrytej z zestawu 2.

5. PODSUMOWANIE

W dalszych badaniach zostanie poruszony temat przełączania się pomiędzy regulatorem PID, a regulatorem PID z siecią neuronową, dla dynamicznie zmieniającego się punktu pracy. Wyniki zostaną porównane z przełączeniem pomiędzy dwoma regulatorami PID oraz zostanie dokonana analiza stanów niustalonych w momencie przełączenia (wartość członu całkującego zerowa w chwili przełączenia regulatora).

LITERATURA

- [1] Astrom K. J. and Hagglund T. H., New tuning methods for PID controllers, Proceedings of the 3rd European Control Conference, 1995.
- [2] Brandt R. D., Lin F., Adaptive interaction and its application to neural networks, Information Sciences, Volume 121, Issues 3–4, 2 December 1999.
- [3] Shahrakia F., Fanaeib M.A., Arjomandzadeha A.R., Adaptive system control with PID neural networks, Chemical Engineering Transactions, No 17, January 2009, s. 1395–1400.
- [4] Sung S.W., Lee I-B., Lee B-K., On-line process identification and automatic tuning method for PID controllers, Chemical Engineering Science, 1998, vol. 53, no 10, s. 1847–1859.
- [5] Tan K.K, Huang S., Ferdons R., Robust self-tuning PID controller for nonlinear systems, Journal of Process Control, 2002, 12, s. 753–761.
- [6] Lis M., Koziński P., Impact of the information about state variables on quality control of neurodriver, Conference archives PTETiS, vol. 31, 2012, Poland, s. 293–296.
- [7] Luoren L., Jinling L., Research of PID Control Algorithm Based on Neural Network, Energy Procedia 13, 2011, s. 6988–6993.

**ADDITION OF SMALL NEURAL NETWORK TO PID CONTROLLER AND ITS
EFFECT ON QUALITY OF CONTROL**

The article attempts to implement PID controller and a small neural network connected together and explore the effect of this combination on the quality of regulation. The test object is a buck converter controlled with current. The main criterion for selection of the study was resource constraints in terms of the control system. Neural network has been compared with one, two and three neurons in the hidden layer for different operating points of the converter.