

## НЕЙРОСЕТЕВАЯ РЕАЛИЗАЦИЯ РЕГУЛЯТОРА ДЛЯ УСТОЙЧИВОГО ОБЪЕКТА\*

В.И. ШИПАГИН

*630087, РФ, г. Новосибирск, пр. Карла Маркса, 20, Новосибирский государственный технический университет, аспирант кафедры автоматики. E-mail: shipagin@mail.ru*

Задача управления некоторыми системами усложняется за счет того, что динамика управляемой конструкции не может быть полностью описана математически. Использование классических PID-регуляторов не дает возможности учесть особенности динамики движения таких систем. Также в результате действия неучтенных внешних факторов возникает проблема с обеспечением устойчивости такой системы. Применение нейросетевых регуляторов призвано решить эти проблемы, так как они способны учитывать динамику системы в режиме реального времени.

В рамках статьи рассматривается эффективность нейросетевого управления устойчивым объектом. Изучается влияние характеристик нейросетевой модели на результативность ее работы. Для обучения нейронной сети в качестве эталонной модели был принят регулятор, синтезированный с использованием полиномиального матричного разложения.

**Ключевые слова:** система управления, нейросетевой регулятор, нейронная сеть, полиномиальное матричное разложение, синтез нейронной сети, машинное обучение

## ВВЕДЕНИЕ

Использование нейросетевого подхода нашло применение в решении широкого класса задач таких, как управление [1], классификация [2–5], кластеризация [2–4, 6], распознавание изображений [7], речи [8, 9] и других [10].

Как видно из вышеперечисленных источников, использование нейросетевого подхода актуально в настоящее время, однако некоторые вопросы недостаточно раскрыты, и из-за этого возникает ряд проблем, среди которых можно выделить следующие: отсутствие однозначных рекомендаций по выбору структуры нейронной сети [2–5], выбор начальных условий [4], недообучение и переобучение моделей [3, 4] и другие.

---

\* Статья получена 18 июля 2019 г.

В настоящей статье изучается возможность управления устойчивым объектом с помощью нейросетевого регулятора. Рассматривается воздействие различных тренировочных выборок на обучаемость нейросетевой модели и впоследствии – эффективность ее управления.

Моделирование системы осуществляется в программном средстве Matlab2013b, модуль Simulink.

## 1. СИНТЕЗ РЕГУЛЯТОРОВ В НЕПРЕРЫВНОМ И ДИСКРЕТНОМ ВИДЕ И ФОРМИРОВАНИЕ ОБУЧАЮЩЕЙ ВЫБОРКИ

Для демонстрации работы нейросетевого регулятора был выбран простой объект:

$$w_o(s) = 1 / (s^2 + 2s + 10). \quad (1)$$

Выполняем синтез непрерывного регулятора с использованием полиномиального матричного разложения [11–13]. Возьмем регулятор следующего вида:

$$w_{reg}(s) = \frac{x_2 s^2 + x_1 s + x_0}{y_2 s^2 + y_1 s + y_0}. \quad (2)$$

Для того чтобы найти параметры  $x_2, x_1, x_0, y_2, y_1, y_0$ , найдем характеристический полином замкнутой системы (ХПЗС):

$$c(s) = x_2 s^2 + x_1 s + x_0 + (s^2 + 2s + 10)(y_2 s^2 + y_1 s + y_0). \quad (3)$$

После раскрытия скобок и объединения параметров по  $s$  получаем уравнения вида

$$\begin{aligned} c(s) = & y_2 s^4 + (2y_2 + y_1)s^3 + (x_2 + 10y_2 + 2y_1 + y_0)s^2 + \\ & + (x_1 + 10y_1 + 2y_0)s + (x_0 + 10y_0). \end{aligned}$$

Пусть полюса системы все равны  $-2$ :

$$c(s) = (s + 2)^4 = s^4 + 8s^3 + 24s^2 + 32s + 16. \quad (4)$$

Получаем систему уравнений, из которой находим параметры:  $x_2, x_1, x_0, y_2, y_1, y_0$ . Для нахождения шести неизвестных по пяти уравнениям допускаем, что  $y_0 = 0$ , тогда  $x_2 = 2, x_1 = -28, x_0 = 16, y_2 = 1, y_1 = 6$ .

В результате получим регулятор, обеспечивающий устойчивость системы управления:

$$w_r(s) = \frac{2s^2 - 28s + 16}{s^2 + 6s} \quad (5)$$

С помощью команды `c2d([2 -28 16],[ 1 6 0], 0.1)` уравнение регулятора преобразуется к дискретному виду с достаточно малым шагом дискретизации 0,1 с:

$$w_r d(s) = \frac{2z^2 - 6,039z + 4,16}{z^2 - 1,549z + 0,5488} \quad (6)$$

Модель системы с непрерывным и дискретным регуляторами реализована в модуле Simulink (рис. 1).

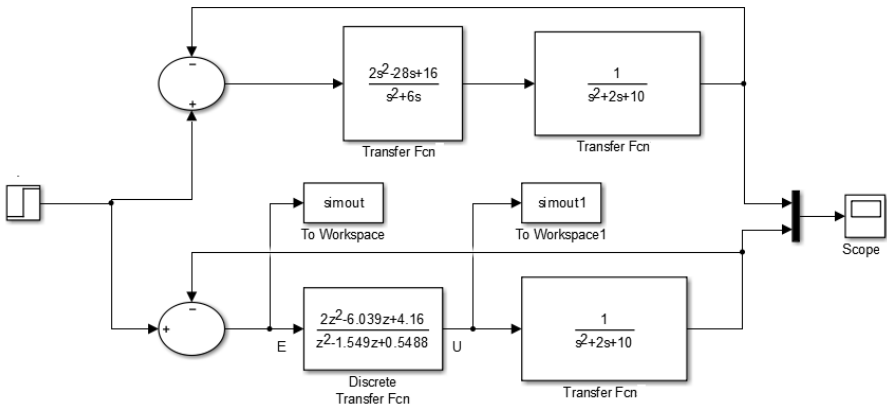


Рис. 1. Модель системы с непрерывным и дискретным регуляторами

Для обучения нейронной сети в качестве эталонной модели был принят дискретный регулятор. Сгенерируем обучающую выборку, состоящую из входных ( $E$ ) и целевых ( $U$ ) данных дискретного регулятора с шагом дискретизации 0,1 с:

зации 0,1 секунды (рис. 1). Данные из Simulink передаются в рабочее пространство Matlab с помощью модулей *simout* и *simout1*.

При воздействии на систему единичным ступенчатым воздействием наблюдаем переходные процессы длительностью 10 секунд, показанные на рис. 2.




Рис. 2. Переходные процессы с дискретным и непрерывным регуляторами

Таким образом, при шаге дискретизации 0,1 секунды и длительности переходного процесса 10 секунд получаем величину обучающей выборки в 101 пару  $E-U$  для одного переходного процесса.

Однако одного ступенчатого воздействия для обучений нейросетевого регулятора недостаточно. Подадим на вход нашей системы 40 ступенчатых сигналов с интервалом в 10 секунд. Выбор значений ступенчатых сигналов осуществляется случайным образом, по нормальному закону распределения (математическое ожидание  $\mu = 0$ , среднеквадратичное отклонение  $\sigma = 0,5$ ). Данные записывались для временного промежутка в 400 секунд (достаточного для завершения 40 различных переходных процессов). Таким образом, получаем два вектора с размерностью  $4001 \times 1$ , записанных в рабочее пространство Matlab.

Выборка разделена на три группы: тренировочная (70 %), проверочная (15 %), тестовая (15 %). Таким образом, для каждого входного вектора  $E$  существует парный ему целевой вектор  $U$ , задающий требуемый выход.

## 2. СИНТЕЗ НЕЙРОСЕТЕВОГО РЕГУЛЯТОРА

Синтез модели нейросетевого регулятора реализован инструментом Neural Network Fitting Tool, входящим в пакет Matlab.

В качестве архитектуры нейронной сети выбрана следующая: десять нейронов в скрытом слое с функцией активации (гиперболический тангенс) и одним нейроном в выходном слое с линейной функцией активации.

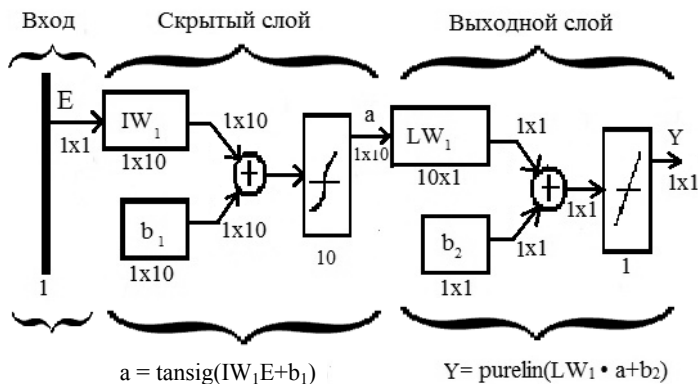


Рис. 3. Структура регулятора на нейронах

При обучении в качестве входных параметров используются данные, взятые из обучающей выборки. На вход нейронной сети подаем входные параметры  $E$  дискретного регулятора. В скрытом слое он умножается на вектор весов  $IW_1$ , имеющий размерность  $1 \times 10$ . Затем этот вектор суммируется с вектором отклонений  $b_1$ , также имеющим размерность  $1 \times 10$ . Результирующий вектор «пропускается» через гиперболическую тангенциальную функцию активации *tansig*. В результате получаем выходной вектор скрытого слоя  $a$ . На этом работа скрытого слоя нейронной сети завершена. Данные передаются на выходной слой.

В выходном слое вектор  $a$  с размерностью  $1 \times 10$  перемножается с вектором весов  $LW_1$  с размерностью  $10 \times 1$ . В результате получается скаляр, который затем суммируется с отклонением  $b_2$ . Этот скаляр пропускается через линейную функцию активации *purelin*. Результатом работы нейронной сети будет являться скаляр  $Y$ .

Для настройки весов нейронной сети применяется алгоритм обратного распространения ошибки. Этот алгоритм рассчитывает возникающую в вы-

ходном слое ошибку (разницу между выходом из нейронной сети  $Y$  и выходом из дискретного регулятора  $U$ ) и вычисляет вектор градиента как функцию весов и смещений [14].

В качестве настраиваемых параметров выступают: веса скрытого слоя  $IW_1(10)$ , отклонения скрытого слоя  $b_1(10)$ , веса выходного слоя  $LW_1(10)$ , отклонение выходного слоя  $b_2(1)$  – итого 31 настраиваемый параметр.

Процесс обучения занял 127 эпох (весь набор данных прошел через нейронную сеть в прямом и обратном направлении 127 раз [15]).

Для проверки работы нейросетевого регулятора подадим на вход системы единичное ступенчатое воздействие.




Рис. 4. Переходные процессы дискретного и нейросетевого регуляторов

Изменим характеристики обучающей выборки, увеличив длину ступенчатого воздействия с 10 до 20 секунд. Таким образом, при 40 ступенчатых воздействиях величина обучающей выборки увеличится до 8001 экземпляра.

После обучения нейросетевая модель быстрее дискретного регулятора выводит нашу систему в статический режим (5 секунд против 10 секунд). Это может быть связано с обучающей выборкой. Большая часть данных представлена статическим режимом системы. При длине ступенчатого воздействия 20 секунд – данных, соответствующих статическому режиму или в непосредственной близости от него, будет около 77,5 %.

Для оптимизации структуры регулятора найдем его статическую характеристику. Из рис. 6 видно, что статическая характеристика нейросетевого регулятора достаточно хорошо аппроксимируется прямой линией  $y = ax + b$ . То есть для реализации регулятора достаточно одного нейрона.




Рис. 5. Переходные процессы дискретного и нейросетевого регуляторов (ступенчатое воздействие – 20 секунд)




Рис. 6. Статическая характеристика нейронного регулятора и ее аппроксимация, соответствующая единичному воздействию

Для единичного ступенчатого воздействия параметры аппроксимирующего нейрона следующие:  $a = -8$ ,  $b = 10$ . Структурная схема нашей системы представлена на рис. 7.




Рис. 7. Структурная схема с нейронным регулятором на одном нейроне

Под каждое задающее воздействие параметры  $a$  и  $b$  будут свои. Нейросетевая модель регулятора «плохо реагирует» на воздействия, отличные от единичного. Чем дальше задающее воздействие от единичного, тем с большей ошибкой регулятор выводит систему в статический режим.

## ЗАКЛЮЧЕНИЕ

В ходе выполнения работы было выяснено следующее:

- выбранной структуры нейронной сети без задержек и величины обучающей выборки достаточно для эмуляции работы выбранного дискретного регулятора для единичного задающего воздействия;
- время переходного процесса у системы с нейронным регулятором существенно меньше по сравнению с эталонной моделью в случае, когда в обучающей выборке преобладают данные о поведении регулятора в статическом режиме объекта;
- в обучающей выборке данными о поведении регулятора при динамическом изменении объекта нельзя пренебрегать. В противном случае регулятор не будет выводить систему в требуемый статический режим;
- нейросетевая модель регулятора плохо реагирует на воздействия, отличные от единичного. Чем дальше задающее воздействие от единичного, тем с большей ошибкой регулятор выводит систему в статический режим.

## СПИСОК ЛИТЕРАТУРЫ

1. Hagan M., Demuth H., Jesús O. A neural network predictive control system for paper mill wastewater treatment // Engineering Applications of Artificial Intelligence. – 2003. – Vol. 16, N 2. – P. 121–129.
2. Haykin S. Neural networks and learning machines. – 3rd ed. – [S. l.]: Pearson Education, 2009. – 938 p.
3. Bishop C. Pattern recognition and machine learning. – New York: Springer, 2007. – 738 p. – (Information science and statistics).



4. *Goodfellow I., Bengio Y., Courville A.* Deep learning. – Cambridge, MA: MIT Press, 2016. – 781 p.
5. *Haykin S., Deng C.* Classification of radar clutter using neural networks // IEEE Transactions on Neural Networks. – 1991. – Vol. 2. – P. 589–600.
6. *Hastie T., Tibshirani R., Friedman J.* The elements of statistical learning: data mining, inference, and prediction. – New York: Springer, 2001. – 552 p.
7. *Krizhevsky A., Sutskever I., Hinton G.E.* ImageNet classification with deep convolutional neural networks // Advances in Neural Information Processing Systems 25 (NIPS 2012). – Lake Tahoe, Nevada, 2012. – P. 1090–1098.
8. *Graves A., Mohamed A., Hinton G.* Speech recognition with deep recurrent neural networks // Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP 2013. – Vancouver, Canada, 2013. – P. 6645–6649.
9. *Deng L., Hinton G.E., Kingsbury B.* New types of deep neural network learning for speech recognition and related applications: an overview // Proceedings of the IEEE International Conference on Acoustic, Speech, and Signal Processing, ICASSP 2013. – Vancouver, Canada, 2013. – P. 8599–8603.
10. *Воевода А.А., Романников Д.О.* Синтез нейронной сети для решения логико-арифметических задач // Труды СПИИРАН. – 2017. – Вып. 54. – С. 205–223.
11. *Воевода А.А., Бобобеков К.М., Шипагин В.И.* Синтез одноканальных регуляторов с использованием факторизации передаточной функции объекта // Сборник научных трудов НГТУ. – 2019. – № 2 (95). – С. 7–17.
12. *Бобобеков К.М.* Полиномиальный метод синтеза одноканальной двухмассовой системы // Сборник научных трудов НГТУ. – 2016. – № 4 (86). – С. 25–36.
13. *Воевода А.А., Бобобеков К.М.* Решение переопределенной линейной системы уравнений при полиномиальном синтезе регуляторов // Современные технологии. Системный анализ. Моделирование. – 2017. – № 4 (56). – С. 84–99.
14. *Медведев В.С., Потемкин В.Г.* Нейронные сети. MATLAB 6 / под общ. ред. В.Г. Потемкина. – М.: Диалог-МИФИ, 2001. – 630 с.
15. *Милютин И.* Эпоха, батч, итерация – в чем различия? // Neurohive: web-сайт. – 2018. – 27 декабря. – URL: <https://neurohive.io/ru/osnovy-data-science/jepoha-razmer-batcha-iteracija/> (дата обращения: 19.12.2019).

**Шипагин Виктор Игоревич**, аспирант кафедры автоматике Новосибирского государственного технического университета. В настоящее время специализируется в области синтеза систем управления техническими системами. E-mail: [shipagin@mail.ru](mailto:shipagin@mail.ru)

DOI: 10.17212/2307-6879-2019-3-4-53-63

## Neural network implementation of a controller for a stable object\*

V.I. Shipagin

*Novosibirsk State Technical University, 20 Karl Marx Prospekt, Novosibirsk, 630073, Russian Federation, the post-graduate student of Department "Automatics". E-mail: shipagin@mail.ru*

The task of controlling some systems is complicated by the fact that the dynamics of the controlled structure cannot be fully described mathematically. Using classic PID controllers does not allow you to take into account the dynamics of movement of such systems. Also, as a result of unrecorded external factors, there is a problem with ensuring the stability of such a system. The use of neural network controllers is intended to solve these problems, since they are able to take into account the dynamics of the system in real time.

This article examines the effectiveness of neural network management of a stable object. The influence of the characteristics of the neural network model on the effectiveness of its work is studied. To train a neural network, a regulator synthesized using polynomial matrix decomposition was adopted as a reference model.

**Keywords:** control system, neural network controller, neural network, polynomial matrix decomposition, neural network synthesis, machine learning

## REFERENCES

1. Hagan M., Demuth H., Jesús O. A neural network predictive control system for paper mill wastewater treatment. *Engineering Applications of Artificial Intelligence*, 2003, vol. 16, no. 2, pp. 121–129.
2. Haykin S. *Neural networks and learning machines*. 3rd ed. Pearson Education, 2009. 938 p.
3. Bishop C. *Pattern recognition and machine learning. Information science and statistics*. New York, Springer, 2007. 738 p.
4. Goodfellow I., Bengio Y., Courville A. *Deep learning*. Cambridge, MA, MIT Press, 2016. 781 p.
5. Haykin S., Deng C. Classification of radar clutter using neural networks. *IEEE Transactions on Neural Networks*, 1991, vol. 2, pp. 589–600.
6. Hastie T., Tibshirani R., Friedman J. *The elements of statistical learning: data mining, inference, and prediction*. New York, Springer, 2001. 552 p.
7. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems 25 (NIPS 2012)*, Lake Tahoe, Nevada, 2012, pp. 1090–1098.
8. Graves A., Mohamed A., Hinton G. Speech recognition with deep recurrent neural networks. *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP 2013*, Vancouver, Canada, 2013, pp. 6645–6649.

---

\* Received 18 July 2019.

9. Deng L., Hinton G.E., Kingsbury B. New types of deep neural network learning for speech recognition and related applications: an overview. *Proceedings of the IEEE International Conference on Acoustic, Speech, and Signal Processing, ICASSP 2013*. Vancouver, Canada, 2013, pp. 8599–8603.

10. Voevoda A.A., Romannikov D.O. Sintez neironnoi seti dlya resheniya logiko-arifmeticheskikh zadach [Synthesis of neural network for solving logical-arithmetic problems]. *Trudy SPIIRAN – SPIIRAS proceedings*, 2017, vol. 54, no. 5, pp. 205–223.

11. Voevoda A.A., Bobobekov K.M., Shipagin V.I. Sintez odnokanal'nykh regulyatorov s ispol'zovaniem faktorizatsii peredatochnoi funktsii ob'ekta [Synthesis of single-channel regulators using factorization of the object transfer function]. *Sbornik nauchnykh trudov Novosibirskogo gosudarstvennogo tekhnicheskogo universiteta – Transaction of scientific papers of the Novosibirsk state technical university*, 2019, no. 2 (95), pp. 7–17.

12. Bobobekov K.M. Polinomial'nyi metod sinteza odnokanal'noi dvukhmassovoi sistemy [A polynomial method for the synthesis of single-channel two-mass system]. *Sbornik nauchnykh trudov Novosibirskogo gosudarstvennogo tekhnicheskogo universiteta – Transaction of scientific papers of the Novosibirsk state technical university*, 2016, no. 4 (86), pp. 25–36.

13. Voevoda A.A., Bobobekov K.M. Reshenie pereopredelennoi lineinoi sistemy uravnenii pri polinomial'nom sinteze regulyatorov [Solution of an overdetermined linear system of equations for polynomial synthesis of regulators]. *Sovremennye tekhnologii. Sistemnyi analiz. Modelirovanie – Modern Technologies. System analysis. Modeling*, 2017, no. 4 (56), pp. 84–99.

14. Medvedev V.S., Potemkin V.G. *Neironnye seti. MATLAB 6* [Neural network. MATLAB 6]. Moscow, Dialog-MIFI Publ., 2001. 630 p.

15. Milyutin I. *Epokha, batch, iteratsiya – v chem razlichiya?* [Epoch vs Batch Size vs Iterations]. *Neurohive*: website, 2018, December 27. (In Russian). Available at: <https://neurohive.io/ru/osnovy-data-science/jepoha-razmer-batcha-iteraciya/> (accessed 19.12.2019).

Для цитирования:

Шипагин В.И. Нейросетевая реализация регулятора для устойчивого объекта // Сборник научных трудов НГТУ. – 2019. – № 3–4 (96). – С. 53–63. – DOI: 10.17212/2307-6879-2019-3-4-53-63.

For citation:

Shipagin V.I. Neurosetevaya realizatsiya regulatora dlya ustoychivogo ob'ekta [Neural network implementation of a controller for a stable object]. *Sbornik nauchnykh trudov Novosibirskogo gosudarstvennogo tekhnicheskogo universiteta – Transaction of scientific papers of the Novosibirsk state technical university*, 2019, no. 3–4 (96), pp. 53–63. DOI: 10.17212/2307-6879-2019-3-4-53-63.