

УДК 004.896, 519.876.5
DOI: 10.15827/0236-235X.139.452-457

Дата подачи статьи: 05.07.22, после доработки: 11.07.22
2022. Т. 35. № 3. С. 452–457

Применение искусственных нейронных сетей в системах автоматического управления магнитной левитацией

А.Г. Коробейников¹, д.т.н., профессор, зам. директора по науке,
Korobeynikov_A_G@mail.ru

¹ Санкт-Петербургский филиал Института земного магнетизма, ионосферы и распространения радиоволн им. Н.В. Пушкова Российской академии наук,
г. Санкт-Петербург, 199034, Россия

В данной работе рассмотрена задача нейросетевой идентификации в системе автоматического управления магнитной левитацией (нейросетевой регулятор).

При проектировании систем автоматического управления сложными техническими динамическими объектами достаточно часто используют математический аппарат на базе искусственных нейронных сетей. Такие сети обладают уникальными преимуществами: возможностями проведения параллельных вычислений, нахождения ранее неизвестных взаимосвязей между входными и выходными последовательностями цифровых сигналов, обеспечения более эффективного управления нелинейными системами за счет применения нелинейных функций активации. Кроме того, применение искусственных нейронных сетей иногда снимает сложности, возникающие при описании некоторых задач в виде аналитических математических моделей.

Решение поставленной задачи осуществлялось на базе методов искусственного интеллекта – хорошо известных рекуррентных искусственных нейронных сетей NARX и LSTM. Обучение этих сетей производилось при помощи алгоритма обратного распространения и метода Левенберга–Марквардта, имеющих хорошую сходимость. Для данной задачи применение обученных искусственных нейронных сетей к тестовым данным показало некоторое преимущество сети NARX по сравнению с LSTM. При этом среднеквадратичная ошибка RSME для сети NARX с 50 скрытыми слоями для данной задачи меньше, чем для сети, имеющей 100 скрытых слоев.

Инструментальным средством для задания архитектуры нейронных сетей, их построения, обучения и тестирования являлась система MATLAB R2021b. Полученные результаты были применены при проектировании автоматических систем управления левитирующими объектами. В настоящее время большинство таких систем разрабатывают и применяют для осуществления перевозок товаров различного назначения, используя эффект магнитной левитации.

Ключевые слова: искусственные нейронные сети, LSTM, NARX, машинное обучение, САУ, магнитная левитация, MATLAB.

Сложности, возникающие при описании некоторых задач в виде аналитических математических моделей и при их решении, вызвали практический и теоретический интерес в предметной области, связанной с развитием методов и систем, которые взаимосвязаны с разными особенностями, возникающими при использовании методов искусственного интеллекта. К ним относят системы нечеткой логики, экспертных оценок, искусственных нейронных сетей (ИНС) и/или их интеграции [1, 2]. Возникающие в этих предметных областях задачи имеют ряд свойств, определяющих сложность их решения, таких как нелинейность математических моделей, неполнота знаний в протекающих процессах, сложность прогнозирования и ситуационного управления, случайный характер внешних воздействий.

При проектировании систем автоматического управления (САУ) сложными техниче-

скими динамическими объектами (СТДО) используют хорошо зарекомендовавший себя мощный математический аппарат на базе ИНС. Нейроуправление СТДО является одним из перспективных направлений, развивающихся на стыке теорий САУ и искусственного интеллекта.

По сравнению с классическими методами, применяемыми при разработке САУ СТДО, можно выделить следующие уникальные для используемых ИНС преимущества:

- проведение параллельных вычислений;
- нахождение ранее неизвестных взаимосвязей между входными и выходными последовательностями цифровых сигналов;
- обеспечение более эффективного управления нелинейными системами за счет применения нелинейных функций активации.

Такие преимущества вызывают большой научный интерес к постановке задач, связан-

ных с практическим применением нейроконтроллеров в САУ СТДО. Тем не менее необходимо отметить и основные недостатки ИНС:

- при обучении ИНС необходимо учитывать эффект переобучения, который может привести к нежелательному результату;
- применение немасштабированных данных на входе ИНС достаточно часто вызывает эффект насыщения, что приводит к нечувствительности ИНС;
- при использовании большого количества переменных ИНС, как правило, возникает эффект «проклятия размерности».

Однако правильный учет этих недостатков даст возможность успешно решить поставленную задачу.

Данная работа базируется на подражающем нейруправлении [3–5]. Основная идея такого управления заключается в обучении нейроконтроллера на примере динамики обычного контроллера с обратной связью, а в качестве обучающей выборки берутся значения на входе и выходе контроллера. Выход является ожидаемой реакцией нейроконтроллера. Для оценки вектора состояния СТДО будут использованы ИНС модели нелинейной авторегрессии с экзогенными входами NARX (Nonlinear Autoregressive with Exogenous Inputs) и модели с долгой краткосрочной памятью LSTM (Long Short-Term Memory) [6, 7].

ИНС LSTM – разновидность архитектуры рекуррентных ИНС, предложенная в 1997 г. З. Хохрайтером и Ю. Шмидхубером [6]. Выбор для исследования LSTM-сети обусловлен ее способностью хорошо прогнозировать временные ряды в ситуациях разделения их значений временными лагами с точно неизвестной продолжительностью ключевых событий.

ИНС NARX тоже имеет архитектуру рекуррентных ИНС, называемых также динамическими моделями NARX [7]. Эти модели хорошо зарекомендовали себя при моделировании нелинейных систем. Кроме того, одним из основных приложений применения моделей NARX являются различные САУ. Анализ использования сетей NARX показывает, что наибольший эффект достигается в случаях, когда имеется зависимость прогнозируемых результатов от входных данных, существующих в предыдущие моменты времени [8].

В качестве объекта управления выбрана система магнитной левитации, являющаяся СТДО. Выбор обусловлен мировым трендом

развития транспортных технологий [9–10]. Вычислительные эксперименты были проведены под управлением Windows 11 при помощи системы MATLAB, позволяющей решать задачи в различных предметных областях [11–13].

Постановка задачи

Целью данной работы является анализ результатов на предмет эффективности использования вышеназванных ИНС для случая САУ левитирующим телом, математическая модель которого имеет следующий вид [14]:

$$\dot{X} = \begin{pmatrix} \frac{dx_1(t)}{dt} \\ \frac{dx_2(t)}{dt} \\ \frac{dx_3(t)}{dt} \end{pmatrix} = \begin{pmatrix} -\frac{R}{L}x_1(t) + \frac{1}{L}u(t) \\ x_3(t) \\ g - \frac{k_m}{m}\left(\frac{x_1(t)}{x_2(t)}\right)^2 - \frac{k_D}{m}x_3(t) \end{pmatrix},$$

где $x_1(t)$ – ток; $x_2(t)$ – вертикальное расстояние от центра левитирующего тела до подложки; $x_3(t)$ – вертикальная скорость левитирующего тела; $u(t)$ – управление; t – время; g – ускорение свободного падения; k_D – коэффициент демпфирования; m – масса левитирующего тела; k_m – постоянный коэффициент, зависящий от параметров катушки; L и R – соответственно индуктивность и сопротивление катушки.

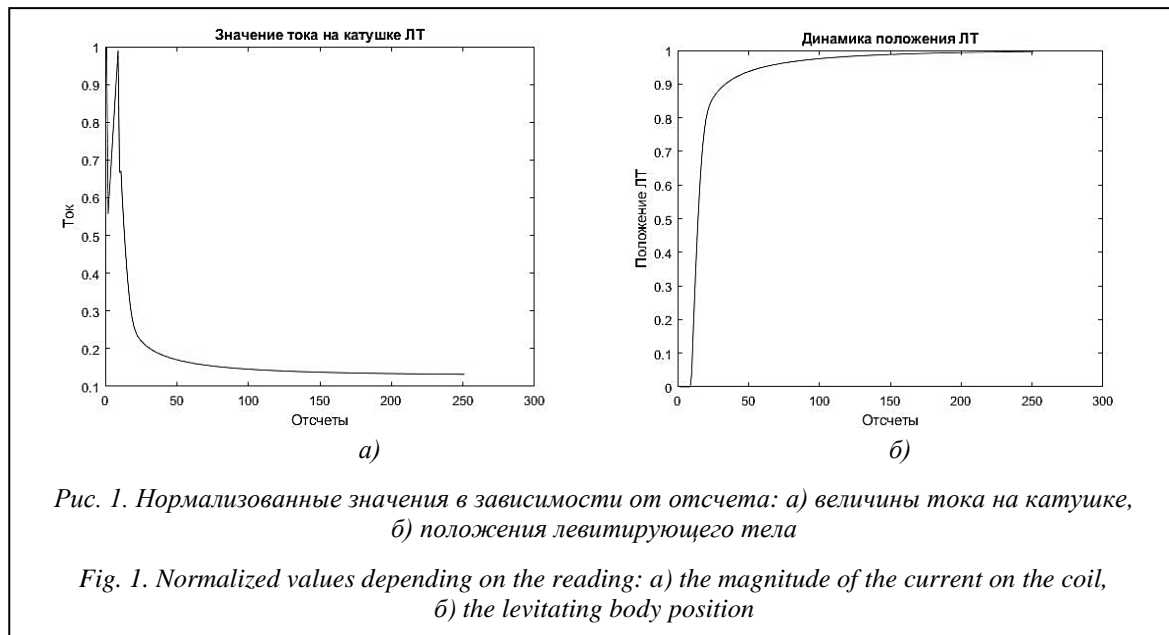
В результате компьютерного моделирования рассчитаны нормализованные значения тока и положения левитирующего тела, графики которых представлены на рисунке 1.

На этих данных необходимо произвести обучение ИНС NARX и LSTM, а затем сравнить результаты.

Создание, обучение и результаты применения обученных нейронных сетей

Сначала создадим и обучим ИНС LSTM с числом скрытых слоев, равным 50 и 100. Кроме этого, зададим величины для прогноза и учета предыдущих значений. В системе MATLAB это можно сделать, например, при помощи следующих операторов:

```
my_Maglev_numFeatures = 1;
my_Maglev_numResponses = 1;
my_Maglev_numHiddenUnits = 50; %100
my_Maglev_layers = [ ...
    sequenceInputLayer(my_Maglev_numFeatures)
    lstmLayer(my_Maglev_numHiddenUnits)
    fullyConnectedLayer(my_Maglev_numResponses)
    regressionLayer];
```



Далее проведем обучение этой сети на 250 эпохах (итерациях) с числом скрытых слоев numHiddenUnits = 50 и numHiddenUnits = 100. Результаты моделирования для numHiddenUnits = 100 представлены на рисунке 2.

Результаты моделирования показали, что при numHiddenUnits = 100 сеть обучается лучше. Для этих данных обученная ИНС LSTM на тестовых данных выдает среднеквадратичную ошибку RSME = 0.0597, для numHiddenUnits = 50, RSME = 0.0728.

Теперь создадим и обучим ИНС NARX с числом скрытых слоев, равным 50 (100). В си-

стеме MATLAB это можно сделать, например, при помощи следующих операторов:

```
my_MagLev_net = narxnet(1:5,1:5,
my_Maglev_numHiddenUnits);
[my_MagLev_net,my_MagLev_tr]=train(my_Mag-
Lev_net,my_MagLev_Xs,my_MagLev_Ts,...
my_MagLev_Xi,my_MagLev_Ai);
```

Структура ИНС NARX с 50 скрытыми слоями и результаты обучения этой ИНС представлены на рисунке 3.

Обучение проводилось при помощи алгоритма оптимизации Левенберга–Марквардта, являющегося модификацией стандартного ал-

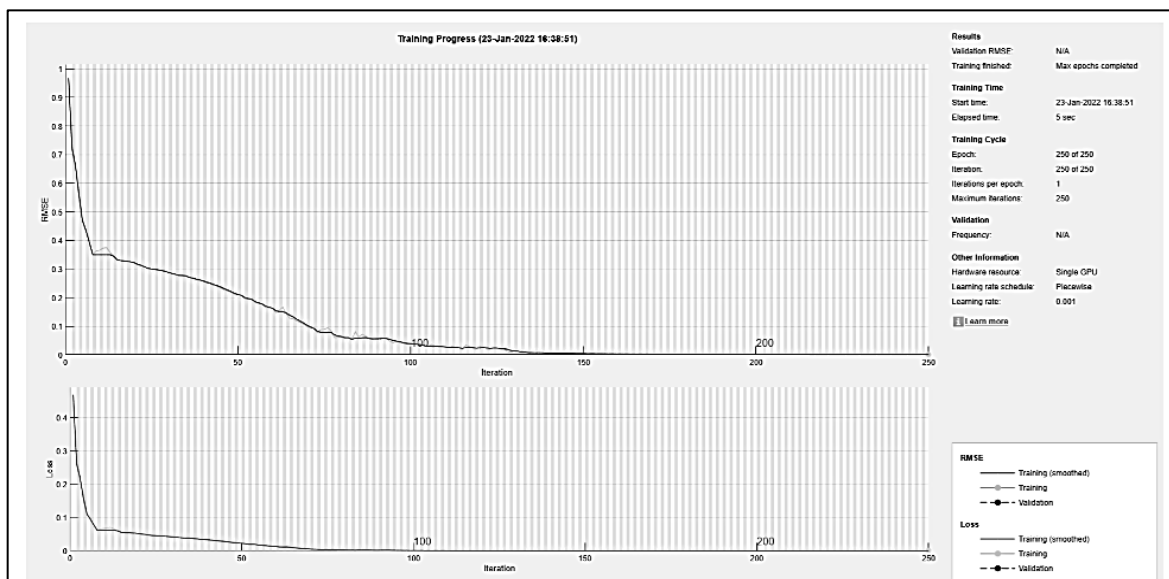


Рис. 2. Обучение ИНС LSTM с числом скрытых слоев, равным 100

Fig. 2. Training LSTM artificial neural network with 100 hidden layers

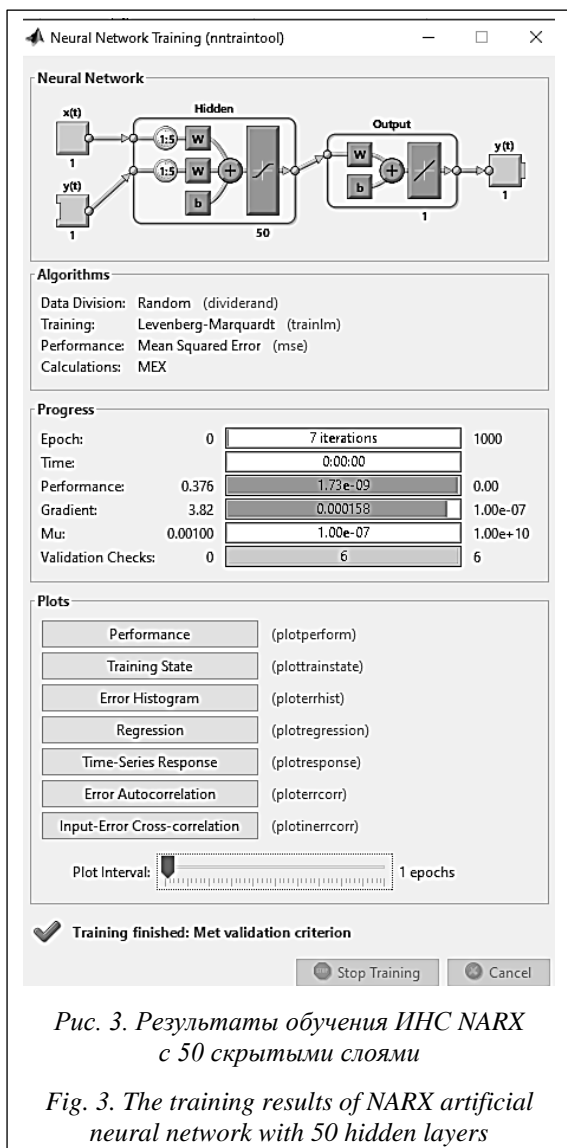


Рис. 3. Результаты обучения ИНС NARX с 50 скрытыми слоями

Fig. 3. The training results of NARX artificial neural network with 50 hidden layers

горитма обратного распространения [15]. Результат в виде графика применения обученной ИНС NARX с числом скрытых слоев, равным 50 (рис. 4), можно получить при помощи оператора `plotresponse(my_MagLev_Ts,my_MagLev_Y)`.

В ходе проведения компьютерного моделирования получены следующие результаты: для ИНС LSTM при количестве скрытых слоев 50 RSME равно $7.28e-02$, при 100 – $5.97e-02$, для

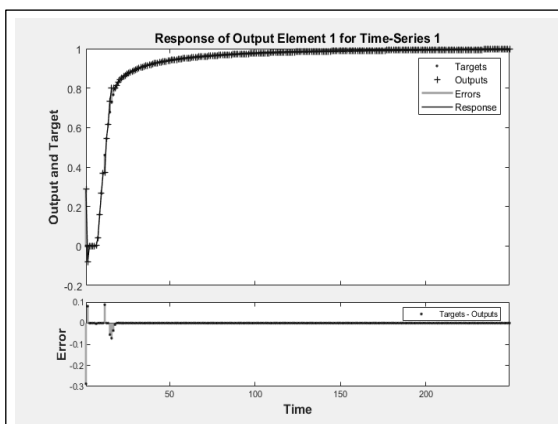


Рис. 4. Результаты применения обученной ИНС NARX, имеющей 50 скрытых слоев

Fig. 4. The results of using the trained NARX artificial neural network with 50 hidden layers

ИНС NARX при количестве слоев 50 RSME равно $4.2559e-04$, при 100 – $5.6e-03$.

Выводы

Анализ представленных результатов показал, что ИНС NARX лучше подходит для САУ магнитной левитации. Кроме того, величина среднеквадратичной ошибки и время обучения для ИНС NARX с 50 скрытыми слоями меньше, чем у ИНС NARX, имеющей 100 скрытых слоев. Поэтому рекомендуется выбирать для рассмотренной задачи ИНС NARX с 50 скрытыми слоями.

В заключение следует отметить, что в данной работе решалась конкретная задача, связанная с нейроуправлением. В общем же случае существует множество нерешенных в этой области задач, например, отсутствие универсальной процедуры анализа устойчивости нелинейных нейроконтроллеров. Известны лишь частные решения для некоторых видов нейроконтроллеров, причем с известной математической моделью объекта управления. Таким образом, можно сделать вывод об актуальности исследований в данной области.

Литература

1. Мунтян Е.Р. Использование нечетких ГН-моделей для представления сложных технических систем // Информатизация и связь. 2021. № 3. С. 55–60. DOI: 10.34219/2078-8320-2021-12-3-55-60.
2. Колоденкова А.Е., Верещагина С.С., Мунтян Е.Р. Разработка единой интеллектуальной системы поддержки принятия решений для диагностирования электротехнического оборудования промышленности // Сб. тр. XIII ВСПУ. 2019. С. 1874–1878.
3. Zhang Y., Wang J. Recurrent neural networks for nonlinear output regulation. Automatica, 2001, vol. 37, no. 8, pp. 1161–1173. DOI: 10.1016/S0005-1098(01)00092-9.

4. Omidvar O., Elliott D.L. *Neural Systems for Control*. NY, Academic Press Publ., 1997, 358 p. DOI: 10.1016/b978-0-12-526430-3.x5000-4.
5. Sigeru O., Marzuki K., Rubiyah Y. *Neuro-control and its Applications*. Springer Publ., 1996, 255 p. DOI: 10.1007/978-1-4471-3058-1.
6. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, vol. 9, no. 8, pp. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
7. Diaconescu E. The use of NARX neural networks to predict chaotic time series. *WSEAS Trans. Comp. Research*, 2008, vol. 3, no. 3, pp. 182–191.
8. Boussaada Z., Curea O., Remaci A., Camblong H., Bellaaj N.M. A nonlinear autoregressive exogenous (NARX) neural network model for the prediction of the daily direct solar radiation. *Energies*, 2018, vol. 11, no. 3, art. 620. DOI: 10.3390/en11030620.
9. Зайцев А.А., Соколова Я.В., Фиронов А.Н. Магнитная левитация – мировой тренд транспортных технологий // Железнодорожный транспорт. 2019. № 3. С. 54–58.
10. Лapidус Б.М., Мачерет Д.А. Перспективная топология высокоскоростной транспортной системы с использованием вакуумно-левитационных технологий // Транспорт Российской Федерации. 2018. № 1. С. 15–21.
11. Korobeynikov A.G., Grishentsev A.Y., Velichko E.N., Aleksanin S.A. et al. Calculation of regularization parameter in the problem of blur removal in digital image. *Optical Memory and Neural Networks*, 2016, vol. 25, no. 3, pp. 184–191. DOI: 10.3103/S1060992X16030036.
12. Коробейников А.Г., Кутузов И.М. Алгоритм обфускации // Кибернетика и программирование. 2013. № 3. С. 1–8. DOI: 10.7256/2306-4196.2013.3.9356.
13. Korobeynikov A.G., Fedosovsky M.E., Zharinov I.O., Shukalov A.V., Gurjanov A.V. Development of conceptual modeling method to solve the tasks of computer-aided design of difficult technical complexes on the basis of category theory. *Int. J. of Applied Engineering Research*, 2017, vol. 12, no. 6, pp. 1114–1122.
14. Коробейников А.Г. Проектирование математической модели системы автоматического управления магнитной левитации // Междунар. журнал гуманитарных и естественных наук. 2021. № 12-2. С. 15–26.
15. Rubio J.d.J. Stability analysis of the modified Levenberg–Marquardt algorithm for the artificial neural network training. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, vol. 32, no. 8, pp. 3510–3524. DOI: 10.1109/TNNLS.2020.3015200.

Software & Systems
DOI: 10.15827/0236-235X.139.452-457

Received 05.07.22, Revised 11.07.22
2022, vol. 35, no. 3, pp. 452–457

Applying artificial neural networks in automatic control systems for magnetic levitation

A.G. Korobeynikov¹, *Dr.Sc. (Engineering), Professor, Deputy Director on Scientific,*
Korobeynikov_A_G@mail.ru

¹ *Pushkov Institute of Terrestrial Magnetism, Ionosphere and Radio Wave Propagation of the Russian Academy of Sciences St.-Petersburg Filial, 199034, Russian Federation*

Abstract. This paper considers the problem of neural network identification in the automatic control system for magnetic levitation (neural network controller). This problem is due to the fact that at present, it is typical to use a mathematical apparatus based on artificial neural networks when designing automatic control systems for complex technical dynamic objects. Such networks have the following unique advantages: the possibility of parallel computing; finding previously unknown relationships between input and output sequences of digital signals; more efficient control of nonlinear systems using nonlinear activation functions. In addition, the use of artificial neural networks sometimes removes the difficulties that arise when describing some problems in the form of analytical mathematical models.

This paper describes the solution for the problem based on artificial intelligence methods – well-known recurrent artificial neural networks NARX and LSTM. These networks were trained using the backpropagation algorithm and the Levenberg–Marquardt method, which have good convergence. For this problem, the application of trained artificial neural networks to test data has shown some advantage of the NARX network compared to LSTM. Moreover, the RSME rms error for the NARX network with 50 hidden layers for this problem is less than for the network with 100 hidden layers.

The MATLAB R2021b system was a tool for setting the architecture of neural networks, their construction, training and testing. The obtained results are applied in designing automatic control systems for levitating objects. Currently, most of these systems are being developed and used to transport goods for various purposes using the effect of magnetic levitation.

Keywords: artificial neural networks, LSTM, NARX, machine learning, ACS, magnetic levitation, MATLAB.

References

1. Muntyan E.R. Using fuzzy GH-models to represent the complex technical systems. *Informatization and Communication*, 2021, no. 3, pp. 55–60. DOI: 10.34219/2078-8320-2021-12-3-55-60 (in Russ.).
2. Kolodenkova A.E., Vereshchagina S.S., Muntyan E.R. Development of a unified intelligent decision support system for diagnosing electrical equipment in the industry. *Proc. XIII All-Russ. Conf. on Management Problems*, 2019, pp. 1874–1878 (in Russ.).
3. Zhang Y., Wang J. Recurrent neural networks for nonlinear output regulation. *Automatica*, 2001, vol. 37, no. 8, pp. 1161–1173. DOI: 10.1016/S0005-1098(01)00092-9.
4. Omidvar O., Elliott D.L. *Neural Systems for Control*. NY, Academic Press Publ., 1997, 358 p. DOI: 10.1016/b978-0-12-526430-3.x5000-4.
5. Sigeru O., Marzuki K., Rubiyah Y. *Neuro-control and its Applications*. Springer Publ., 1996, 255 p. DOI: 10.1007/978-1-4471-3058-1.
6. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, vol. 9, no. 8, pp. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
7. Diaconescu E. The use of NARX neural networks to predict chaotic time series. *WSEAS Trans. Comp. Research*, 2008, vol. 3, no. 3, pp. 182–191.
8. Boussaada Z., Curea O., Remaci A., Camblong H., Bellaaj N.M. A nonlinear autoregressive exogenous (NARX) neural network model for the prediction of the daily direct solar radiation. *Energies*, 2018, vol. 11, no. 3, art. 620. DOI: 10.3390/en11030620.
9. Zaitsev A.A., Sokolova Ya.V., Fironov A.N. Magnetic levitation as a global trend in transport technologies. *Railway Transport*, 2019, no. 3, pp. 54–58 (in Russ.).
10. Lapidus B.M., Macheret D.A. Perspective topology of a high-speed transport system using vacuum levitation technologies. *Transport of the Russian Federation*, 2018, no. 1, pp. 15–21 (in Russ.).
11. Korobeynikov A.G., Grishentsev A.Y., Velichko E.N., Aleksanin S.A. et al. Calculation of regularization parameter in the problem of blur removal in digital image. *Optical Memory and Neural Networks*, 2016, vol. 25, no. 3, pp. 184–191. DOI: 10.3103/S1060992X16030036.
12. Korobeynikov A.G., Kutuzov I.M. Obfuscation algorithm. *Cybernetics and Programming*, 2013, no. 3, pp. 1–8. DOI: 10.7256/2306-4196.2013.3.9356 (in Russ.).
13. Korobeynikov A.G., Fedosovsky M.E., Zharinov I.O., Shukalov A.V., Gurjanov A.V. Development of conceptual modeling method to solve the tasks of computer-aided design of difficult technical complexes on the basis of category theory. *Int. J. of Applied Engineering Research*, 2017, vol. 12, no. 6, pp. 1114–1122.
14. Korobeynikov A.G. Designing a mathematical model of a magnetic levitation automatic control system. *Int. J. of Humanities and Natural Sciences*, 2021, no. 12-2, pp. 15–26 (in Russ.).
15. Rubio J.d.J. Stability analysis of the modified Levenberg–Marquardt algorithm for the artificial neural network training. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, vol. 32, no. 8, pp. 3510–3524. DOI: 10.1109/TNNLS.2020.3015200.

Для цитирования

Коробейников А.Г. Применение искусственных нейронных сетей в системах автоматического управления магнитной левитацией // Программные продукты и системы. 2022. Т. 35. № 3. С. 452–457. DOI: 10.15827/0236-235X.139.452-457.

For citation

Korobeynikov A.G. Applying artificial neural networks in automatic control systems for magnetic levitation. *Software & Systems*, 2022, vol. 35, no. 3, pp. 452–457 (in Russ.). DOI: 10.15827/0236-235X.139.452-457.