

Синтез нейросетового регулятора для линеаризованной модели объекта – два перевернутых маятника на тележке

А. А. Воевода, В. И. Шипагин✉

Новосибирский государственный технический университет «НЭТИ», Новосибирск, Россия

✉ shipagin@mail.ru

Аннотация. В настоящей статье продемонстрирована процедура синтеза нейросетового регулятора для линеаризованной модели объекта «два перевернутых маятника на тележке». Особенностью данной модели объекта можно считать его неквадратную матричную передаточную функцию и меньшее количество входных воздействий, чем выходных. Задача управления состоит в стабилизации углов перевернутых маятников в устойчивом положении и перевод положения тележки в заданное значение. Отличительной чертой продемонстрированной процедуры синтеза нейрорегулятора являются детерминированные выбор архитектуры и инициализация весовых коэффициентов нейронной сети. Данные о выборе архитектуры и о значениях инициализируемых весовых коэффициентов для нейросетового регулятора основаны на информации о передаточной функции регулятора, полученного модальным методом, использующим полиномиальное матричное разложение системы. Приводятся рекомендации к структурным преобразованиям нейросетового регулятора, содержащего рекуррентные связи. Они необходимы для дальнейшего обучения нейросетового регулятора с детерминированным подходом к инициализации весовых коэффициентов, применяемым в демонстрируемой процедуре синтеза. В результате усложнения структуры и дальнейшего обучения, полученного нейросетового регулятора, удастся повысить эффективность работы системы автоматического управления по сравнению с системой, использующей регулятор, полученный модальным методом.

Ключевые слова: нейрорегулятор, рекуррентная нейронная сеть, обучение нейронной сети, инициализация весовых коэффициентов, структурные преобразования

Для цитирования: Воевода А. А., Шипагин В. И. Синтез нейросетового регулятора для линеаризованной модели объекта – два перевернутых маятника на тележке // Изв. СПбГЭТУ «ЛЭТИ». 2023. Т. 16, № 1. С. 39–52. doi: 10.32603/2071-8985-2023-16-1-39-52.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Original article

Synthesis of a Neural Network Controller for a Linearized Model of the Plant – Two Inverted Pendulums on a Cart

А. А. Voevoda, V. I. Shipagin✉

Novosibirsk State Technical University, Novosibirsk, Russia

✉ shipagin@mail.ru

Abstract. This article demonstrates the procedure for the synthesis of a neural network controller for a linearized model of the plant «two inverted pendulums on a cart». A feature of this plant can be considered its non-square matrix transfer function and the number of input effects is less than the number of output effects. The task of the control is to stabilize the angles of the inverted pendulums in a stable position and transfer the position of the cart to a set value. A distinctive feature of the demonstrated procedure for the synthesis of a neuroregulator is the deterministic choice of architecture and initialization of the weighting coefficients of the neural network. Data on the choice of architecture and on the values of initialized weighting coefficients for the neural

network controller are obtained based on information about the transfer function of the controller obtained by the modal method using the polynomial matrix decomposition of the system. Recommendations for structural transformations of a neural network regulator containing recurrent connections are given. They are necessary for further training of a neural network controller with a deterministic approach to initialization of weight coefficients used in the demonstrated synthesis procedure. As a result of the complexity of the structure and further training of the neural network controller obtained, it is possible to increase the efficiency of the automatic control system compared with the system using the controller obtained by the modal method.

Keywords: neuroregulator, recurrent neural network, neural network training, initialization of weighting coefficients, structural transformations

For citation: Voevoda A. A., Shipagin V. I. Synthesis of a Neural Network Controller for a Linearized Model of the Plant – Two Inverted Pendulums on a Cart // LETI Transactions on Electrical Engineering & Computer Science. 2023. Vol. 16, no. 1. P. 39–52. <https://doi.org/10.32603/2071-8985-2023-16-1-39-52>.

Conflict of interest. The authors declare no conflicts of interest.

Введение. Современные технологические системы предъявляют повышенные требования к качествам работы систем автоматического управления (далее – САУ). Например, требуется удерживать переходный процесс внутри области допустимых значений регулируемой величины. В этом случае вероятно ситуация с повышением качества уже имеющейся САУ. Одним из направлений, которое может помочь в решении данного вопроса, может служить внедрение нейросетевых регуляторов [1]–[4]. Однако при их использовании существует ряд неформализованных вопросов, к которым относятся определение архитектуры и инициализации весовых коэффициентов нейронной сети [5], [6].

В данной статье приводится алгоритм синтеза нейросетевого регулятора с описанной процедурой выбора архитектуры нейронной сети и инициализации весовых коэффициентов. Приведенный алгоритм может быть применен в случае имеющейся сформированной САУ с целью, например, повышения ее качества работы или учета нелинейных параметров модели объекта [7], [8]. Для формирования нейросетевого регулятора используется информация о передаточной функции регулятора, полученного модальным методом, использующим полиномиальное матричное разложение системы (далее – полиномиальный регулятор).

Демонстрация действий процедуры синтеза нейросетевого регулятора проведена на примере линеаризованной модели объекта «два перевернутых маятника на тележке» (two inverted pendulums on a cart), приведенной в [9], [10]. Системы вида «перевернутый маятник на тележке» – это классический пример неустойчивого объекта, который позволяет отрабатывать различные методики син-

теза САУ. Системы такого вида рассматривались авторами публикаций [11]–[18]. К особенностям данных систем относятся их неминимально фазовый характер с устойчивым положением перевернутого маятника в верхнем нулевом положении. В данной статье система «два перевернутых маятника на тележке» рассматривается как многоканальная, с неквадратной матричной передаточной функцией. При этом управление данной системой усложняется в силу того, что количество входных каналов меньше, чем количество выходных каналов. Управляемость систем с меньшим числом входных воздействий, чем выходных величин, рассмотрена в [19].

Кроме всего прочего в ходе процедуры синтеза нейросетевого регулятора было выяснено, что довольно часто возникает необходимость синтеза архитектуры нейронной сети, имеющей в своем составе обратные связи (так называемые рекуррентные нейронные сети). На практике при обучении стандартных рекуррентных нейронных сетей могут возникать проблемы, связанные с экспоненциальным затуханием или ростом градиента. Они были подробно изучены в [20]–[24]. Для обучения рекуррентных нейронных сетей используются различные подходы, к которым, например, можно отнести использование модифицированных алгоритмов обучения с учителем на базе методов оптимизации по типу алгоритма обратного распространения ошибки во времени (Back Propagation Through Time, ВРТТ), рекуррентное обучение в реальном времени (Real-Time Recurrent Learning, RTRL), рекуррентное обратное распространение (Recurrent Back Propagation, RBP). В данной статье применен подход, основанный на алгоритме обучения с учителем. При этом сигналы с обратных связей рассматриваются

как отдельные входные сигналы. Данный подход похож на применяемый в сетях Элмана и Джордана, однако в нашем случае контекстные нейроны не используются, вместо этого преобразование проводится на уровне структурной схемы регулятора. В результате задача обучения упрощается и сводится к обычным алгоритмам обучения нейронной сети прямого распространения. В этом случае удастся сохранить необходимую архитектуру нейронной сети и использовать детерминированный подход к инициализации весовых коэффициентов. Это необходимо для того, чтобы начало обучения нейронного регулятора приходилось на параметры, обеспечивающие устойчивое поведение в САУ (необходимое требование алгоритма синтеза нейронного регулятора, приведенного в [7], [8]).

Постановка задачи. Таким образом, цель настоящей статьи состоит в демонстрации работы алгоритма синтеза нейросетевого регулятора с детерминированными архитектурой и инициализацией весовых коэффициентов нейронной сети. При этом введение в САУ нейросетевого регулятора позволяет повысить качество процессов регулирования и в дальнейшем учесть некоторые нелинейные характеристики модели объекта. Одновременно с этим даются рекомендации по преобразованию нейросетевых регуляторов, содержащих рекуррентные связи, к сетям прямого распространения. Это необходимо для решения вопроса об обучаемости нейронной сети при необходимости детерминированной инициализации весовых коэффициентов.

Выбор среды для разработки программы.

Для проведения экспериментов и демонстрации

полученных результатов использовались пакет прикладных программ для технических вычислений MatLab R2021a и система имитационного блочного моделирования динамических систем Simulink ver. 10.3 (R2021a).

Блок-схема алгоритма. На рис. 1 представлен алгоритм синтеза нейросетевого регулятора в виде блок-схемы. Приведем пояснения по каждому блоку:

1. «Данные САУ» – здесь обозначается сформированная САУ. В качестве регулятора может быть использован полиномиальный регулятор. Эта информация необходима для выбора архитектуры и весовых коэффициентов нейросетевого регулятора.

2. «Шаг 1. Получение дискретного вида регулятора. Выбор шага дискретизации» – переводим регулятор из непрерывного в дискретный вид. Необходимо выбрать шаг дискретизации таким образом, чтобы переходные процессы на выходе САУ имели устойчивый характер.

3. «Шаг 2. Структурный вид дискретного регулятора» – по дискретному виду передаточной функции регулятора формируется регулятор в структурном виде.

4. «Шаг 3. Преобразование структурного вида регулятора» – данный шаг необходим в случае, если в полученном структурном виде имеются обратные связи. Он позволит перейти от рекуррентного вида сети к сети прямого распространения. Это позволит упростить процедуру обучения нейросетевого регулятора.

5. «Шаг 4. Регулятор нейросетевого вида» – переводим структурный вид регулятора в нейросетевой. При этом архитектура и весовые

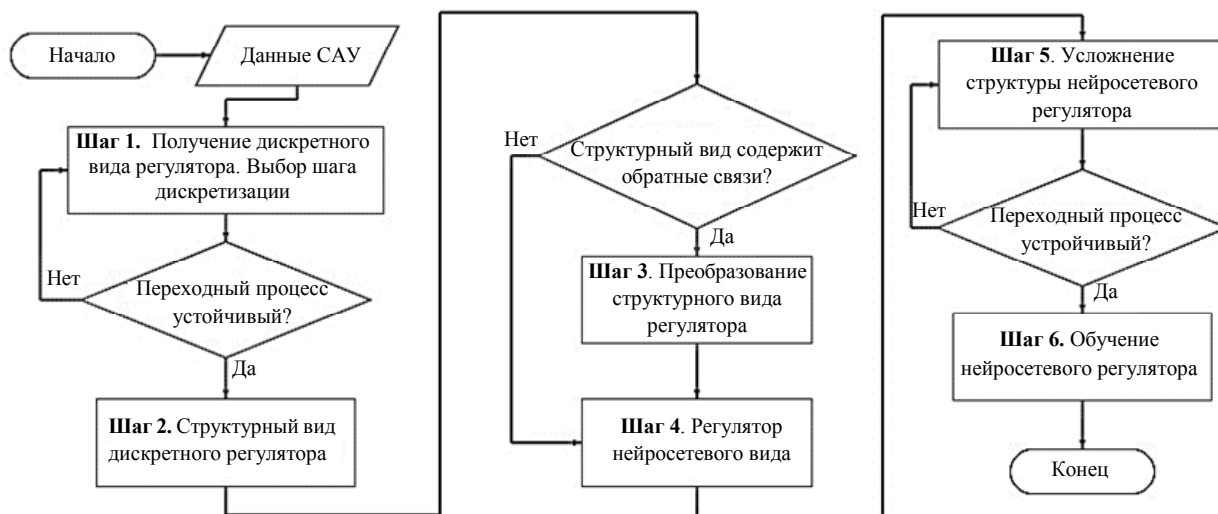


Рис. 1. Блок-схема алгоритма синтеза нейросетевого регулятора
Fig. 1. Block diagram of the neural network controller synthesis algorithm

коэффициенты определяются согласно структуре и числовым коэффициентам дискретного регулятора. Приводится таблица соответствия элементов нейронной сети элементам регулятора структурного вида.

6. «Шаг 5. Усложнение архитектуры нейросетевого регулятора» – здесь может быть как замена некоторых функций активации с линейных на нелинейные, так и добавление новых слоев и увеличение количества нейронов в слое. На этом шаге происходит нормирование весовых коэффициентов с целью обеспечения устойчивой работы полученной САУ, использующей усложненный нейросетевой регулятор.

Обучение нейросетевого регулятора происходит по типу обучения с учителем. Формируется учебная выборка из работы непрерывного регулятора.

1. Описание системы автоматического управления линейризованной моделью объекта «два перевернутых маятника на тележке». В данном разделе будет рассмотрен линейризованная модель объекта «два перевернутых маятника на тележке» в многоканальном виде. Особенностью данной модели объекта можно считать ее неквадратную матричную передаточную функцию с числом входных воздействий меньшим чем число выходных воздействий. Воспользуемся уже сформированной САУ, приведенной в [10], и, наконец, обозначим цель управления системой.

Для примера синтеза нейросетевого регулятора была выбрана линейризованная модель системы «два перевернутых маятника на тележке» (рис. 2), описанная в [9].




Рис. 2. Линейризованная модель объекта «два перевернутых маятника на тележке»
Fig. 2. Linearized model of the object «two inverted pendulums on a trolley»

Для малых углов θ_1 и θ_2 уравнения движения данной системы выглядят следующим образом:

$$\begin{aligned} M\dot{v} &= -mg\theta_1 - mg\theta_2 + u; \\ m(\dot{v} + l_1\ddot{\theta}_1) &= mg\theta_1; \\ m(\dot{v} + l_2\ddot{\theta}_2) &= mg\theta_2, \end{aligned} \quad (1)$$

где v – скорость тележки; u – внешнее воздействие, приложенное к тележке; M – масса тележки; θ_1, θ_2 – углы первого и второго перевернутых маятников соответственно; l_1, l_2 – длины стержней первого и второго маятников соответственно; m – масса каждого маятника. Т. е. данная система будет иметь один входной канал u и три выходных канала θ_1, θ_2, x . Структурная схема, составленная по системе уравнений (1), будет выглядеть, как показано на рис. 3.

Расчет регулятора проводился для следующих параметров модели: $M = 10$ кг, $m = 1$ кг, $l_1 = 1$ м,

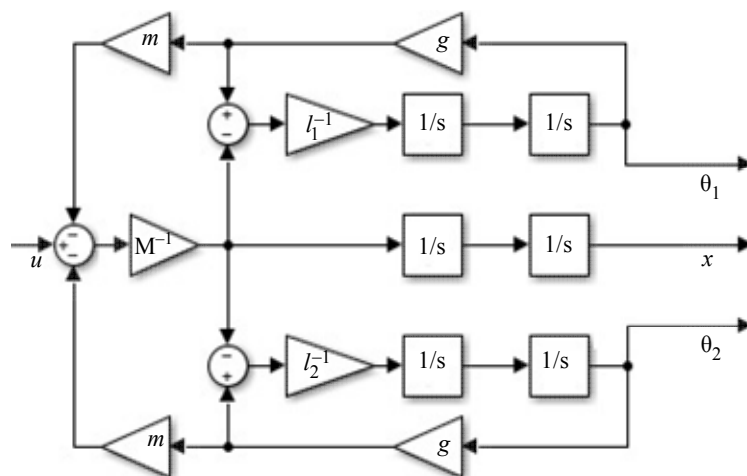


Рис. 3. Блок-схема линейризованной модели объекта
Fig. 3. Block diagram of the linearized plant model

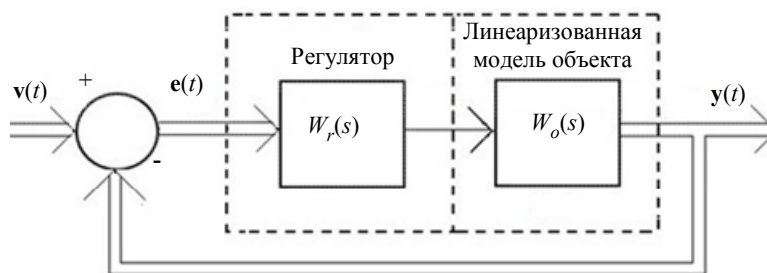


Рис. 4. Система автоматического управления

Fig. 4. Automatic control system

$l_2 = 2$ м, $g = 10$ м/с². Рассмотрим данную многоканальную систему с задачей стабилизации углов отклонений маятника в точке $\theta_1 = \theta_2 = 0^\circ$. При этом потребуем также перемещения каретки в необходимое положение x .

Синтез полиномиального регулятора проведен модальным методом, использующим полиномиальное матричное разложение системы согласно алгоритму синтеза, описанному в [10]. Регулятор расположим в прямой связи с объектом (рис. 4), где $\mathbf{v}(t)$, $\mathbf{y}(t)$, $\mathbf{e}(t) \in R^{3 \times 1}$ – векторы уставки, выхода и ошибки между выходом и уставкой системы соответственно, при этом $\mathbf{e}(t) = \mathbf{y}(t) - \mathbf{v}(t)$. В результате был получен следующий регулятор¹:

$$W_r(s) = \frac{1}{s+7} \begin{pmatrix} -3507s - 11\,061 \\ 3278s + 7074 \\ 7s + 1 \end{pmatrix}^T. \quad (2)$$

Таким образом, изначально имеем сформированную САУ для линеаризованной модели «два перевернутых маятника на тележке», представленную на рис. 3, с полиномиальным регулятором (2). Важно отметить, что данная система строилась, исходя из требований стабилизации углов отклонений маятника в точке $\theta_1 = \theta_2 = 0^\circ$ и выполнения задания по перемещению тележки в заданное положение $x = \hat{x}$. Продемонстрируем процедуру синтеза нейросетевого регулятора и внедрим полученный нейросетевой регулятор в САУ вместо полиномиального регулятора (2). Усложняя архитектуру нейронной сети улучшим качественные характеристики переходных процессов по сравнению с САУ с использованием полиномиального регулятора (2).

2. Синтез нейросетевого регулятора. В настоящем разделе приводится алгоритм синтеза нейросетевого регулятора с использованием ин-

формации о текущей САУ, представленной на рис. 3, с регулятором (2). Применение нейросетевого регулятора в дальнейшем будет необходимо для повышения качества процессов регулирования. В процессе применения данного алгоритма решается вопрос об обучении нейросетевого регулятора рекуррентного типа с детерминированной инициализацией весовых коэффициентов нейронной сети.

Применим алгоритм синтеза нейросетевого регулятора, продемонстрированный на блок-схеме (рис. 1). На *первом шаге* преобразуем модель регулятора (2) от непрерывного к дискретному времени с помощью Z-преобразования. Дискретизацию будем проводить с помощью процедуры «c2d» пакета программ MatLab с методом дискретизации «zero-order hold». Шаг дискретизации выбираем опытным путем до «приемлемого результата» переходных процессов системы (в данном случае выбран шаг дискретизации равный 0.01 с). Передаточная функция регулятора в дискретном виде

$$W_r(z) = \frac{1}{z - 0.9324} \begin{pmatrix} -3507z + 3400 \\ 3278z - 3210 \\ 7z - 6.99 \end{pmatrix}^T. \quad (3)$$

Переходная функция системы представлена на рис. 5.

Как видно из рисунка, качество переходных процессов на выходе системы с использованием дискретного регулятора понизилось. Увеличилась колебательность и время переходного процесса. Для дальнейшего применения алгоритма синтеза нейросетевого регулятора необходимо применение дискретного регулятора, который обеспечивает устойчивый характер переходных процессов на выходе системы, при этом их качество принципиального значения не имеет.

На *втором шаге* необходимо представить передаточную функцию дискретного регулятора в структурном виде. Для этого в (3) выделим минимальное число звеньев задержки z^{-1} . Получим структурную схему, представленную на рис. 6.

Как видно из рис. 6, как и для регулятора в непрерывном времени (рис. 3), он будет иметь

¹ Так как цель статьи не состоит в демонстрации модального метода, использующего полиномиальное матричное разложение, для краткости изложения расчеты в данной статье были опущены. В качестве желаемых полюсов были выбраны полюса, равные -1 .

неквадратную структуру (т. е. с неравным числом входных и выходных каналов²). В данном случае на вход регулятора поступает вектор $e = (\bar{\theta}_1 - \theta_1 \quad \bar{\theta}_2 - \theta_2 \quad \bar{x} - x)^T$, состоящий из ошибок между заданиями: на желаемое положение

тележки \bar{x} , на углы первого и второго перевернутых маятников соответственно $\bar{\theta}_1, \bar{\theta}_2$ (согласно постановке задачи, они всегда задаются нулевыми) и выходами линеаризованной модели объекта θ_1, θ_2, x соответственно.

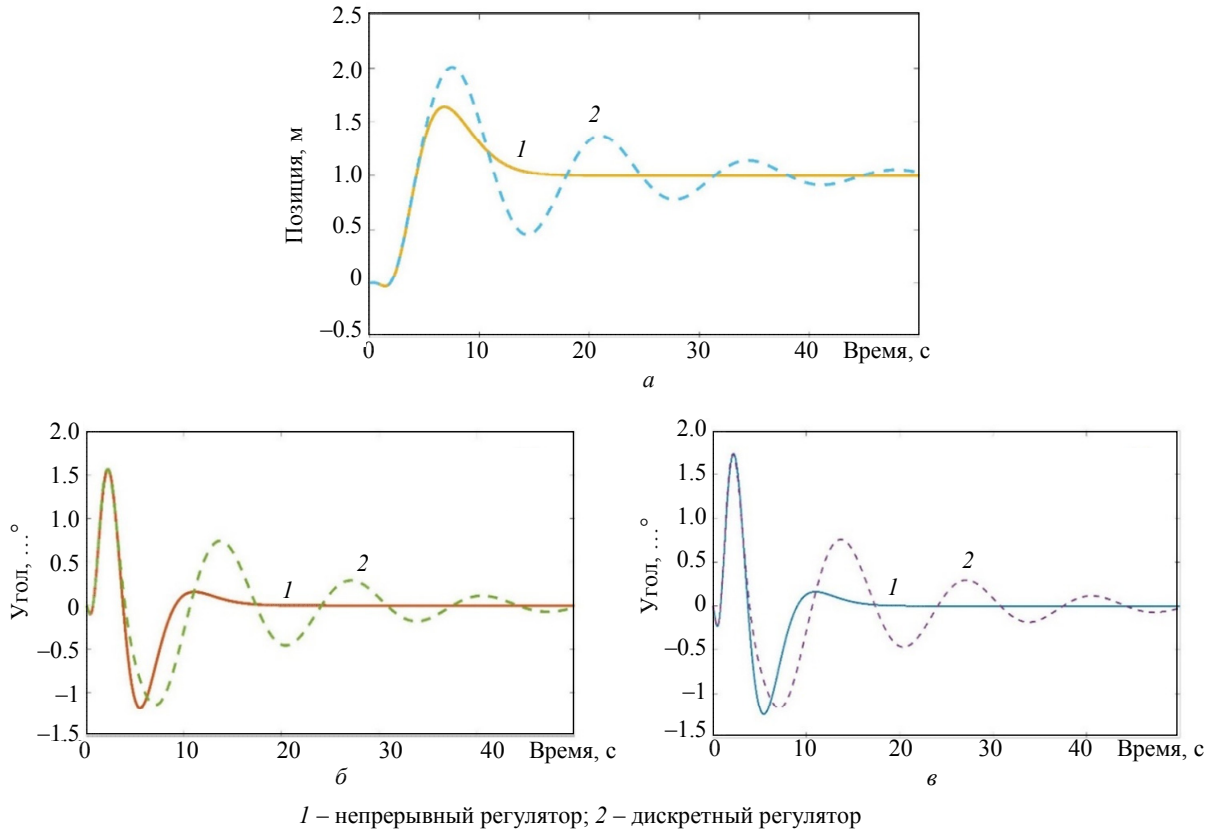


Рис. 5. Переходные процессы для системы автоматического управления с непрерывным и дискретными регуляторами (а – для выхода системы, соответствующего положению тележки; б – для выхода системы, соответствующего углу первого перевернутого маятника; в – для выхода системы, соответствующего углу второго перевернутого маятника)
Fig. 5. Transients for automatic control systems with continuous and discrete regulators (а – for the output of the system corresponding to the position of the cart; б – for the output of the system corresponding to the angle of the first inverted pendulum; в – for the output of the system corresponding to the angle of the second inverted pendulum)

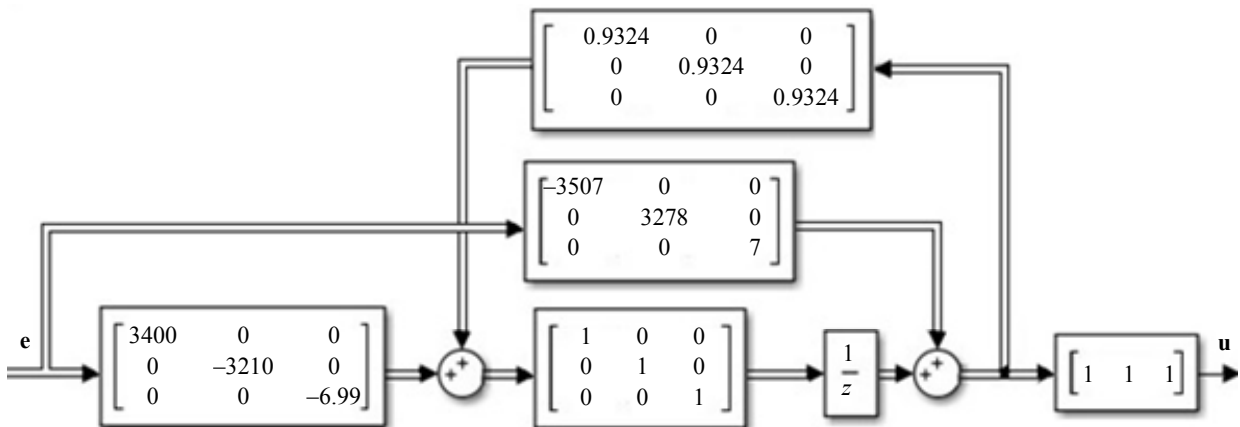


Рис. 6. Блок-схема дискретного регулятора
Fig. 6. Block diagram of a discrete regulator

² Подробнее о неквадратных объектах можно прочитать в [13]. На рис. 6 векторные связи обозначены двойной линией.

Как видно из рис. 6, структурная схема получилась с обратными связями. Это может негативно сказаться на процессе обучения, что и будет

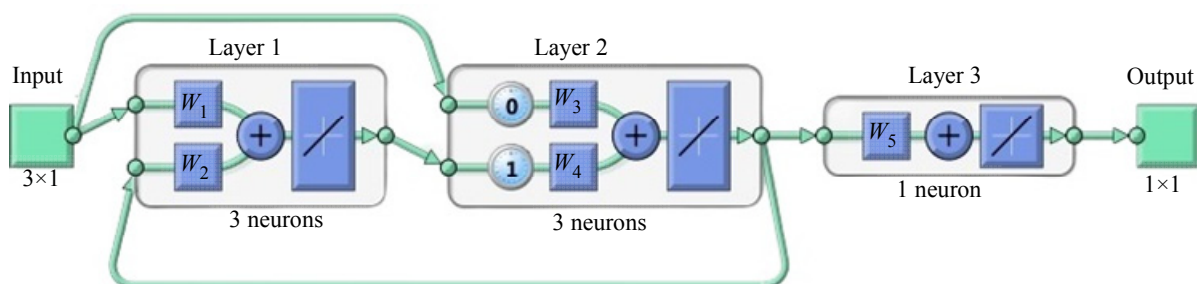


Рис. 7. Нейросетевая реализация дискретного регулятора
 Fig. 7. Neural network implementation of a discrete regulator

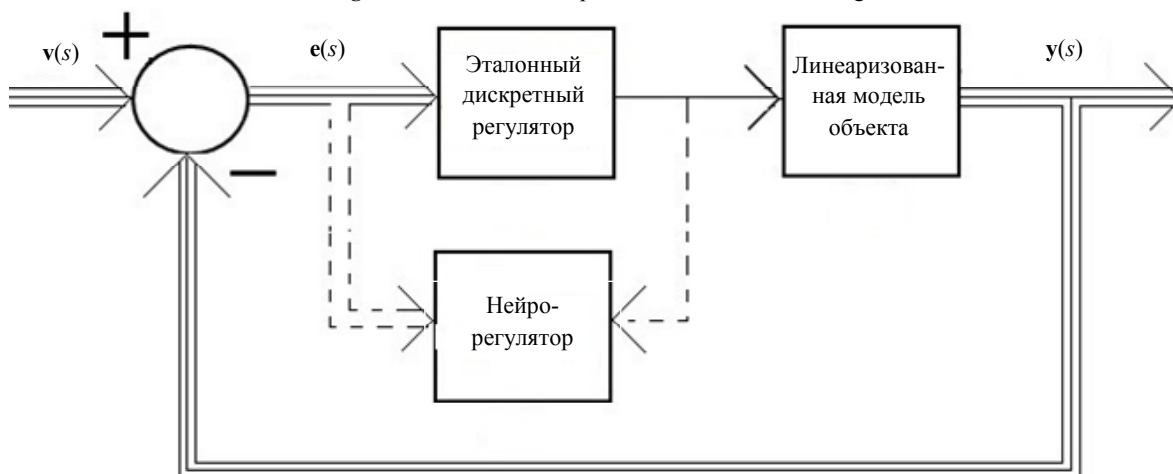


Рис. 8. Структурная схема обучения нейрорегулятора
 Fig. 8. Block diagram of neuroregulator training

Соответствие элементов структурной схемы регулятора
 Compliance of the elements of the structural scheme of the regulator

Элемент структурной схемы	Элемент нейронной сети
Сумматор	Нейрон с линейной функцией активации
Коэффициенты усиления (элементы числовых матриц)	Весовые коэффициенты нейронной сети ³ : $\mathbf{W}_i \in R^{1 \times 3}, i = \overline{1,5}$
Элемент $1/z$	Звено запаздывания в канале нейронной сети

продемонстрировано далее. Для демонстрации сложности настройки нейросетевого регулятора сначала пропустим шаг, связанный со структурными преобразованиями (*третий шаг*), и в дальнейшем к нему вернемся.

На *четвертом шаге* сформируем нейросетевой регулятор, используя информацию о дискретном регуляторе \mathcal{Z} , полученном модальным методом, использующим полиномиальное матричное разложение. Обратим внимание на то, что работа полученного нейросетевого регулятора полностью повторяет характеристики дискретного регулятора. На рис. 7 представлена структурная схема нейрорегулятора.

³ Для того чтобы указать, что, например, \mathbf{W}_i – это вектор с размерностью 1×3 , будем использовать запись $\mathbf{W}_i \in R^{1 \times 3}$. При этом значения данного вектора лежат в области множества вещественных чисел.

Она получена заменой элементов структурной схемы регулятора (рис. 6) элементами нейронной сети согласно таблице соответствия. Таблица соответствия элементов структурной схемы регулятора элементам нейросетевого регулятора разработана на основании [7], [8], [11], [25], в которых приводятся примеры синтеза нейросетевого регулятора для систем, содержащих модели многоканальных объектов.

Настроим весовые коэффициенты данного нейросетевого регулятора по алгоритму обучения «с учителем» и в качестве обучающей выборки будем использовать выборку, полученную при работе дискретного регулятора \mathcal{Z} . На рис. 8 штриховой линией продемонстрирован процесс формирования учебной выборки для нейрорегулятора из входных и выходных значений эталонного дискретного регулятора. Подобное обозначение не ново и применялось в [7], [8], [26].

В связи с тем, что данный нейросетевой регулятор полностью дублирует работу дискретного регулятора и переходные процессы на выходе САУ идентичны, настройку данного регулятора осуществлять не нужно. Однако при обучении нейросетевого регулятора происходит несколько шагов его настройки и получившийся в результате регулятор не справляется с управлением моделью объекта. Система выходит из равновесия. Напомним, что при этом начальные весовые значения исходного нейросетевого регулятора позволяли управлять данной системой на уровне дискретного регулятора, т. е. при обучении произошло ухудшение характеристик регулятора.

Предположим, что это может быть связано с наличием обратных связей в структуре нейросетевого регулятора. Таким образом, необходимо приступить к пропущенному *третьему шагу* в предложенном нами алгоритме и провести некоторые структурные преобразования дискретного регулятора в схеме, представленной на рис. 6.

Структурные преобразования дискретного регулятора необходимы для переноса обратных связей за его пределы, что позволит в дальнейшем уйти от рекуррентных нейронных сетей к сетям прямого распространения. Предположим, что это также позволит устранить проблему настройки нейросетевого регулятора при использовании




Рис. 9. Блок-схема преобразованного дискретного регулятора
 Fig. 9. Block diagram of the converted discrete controller

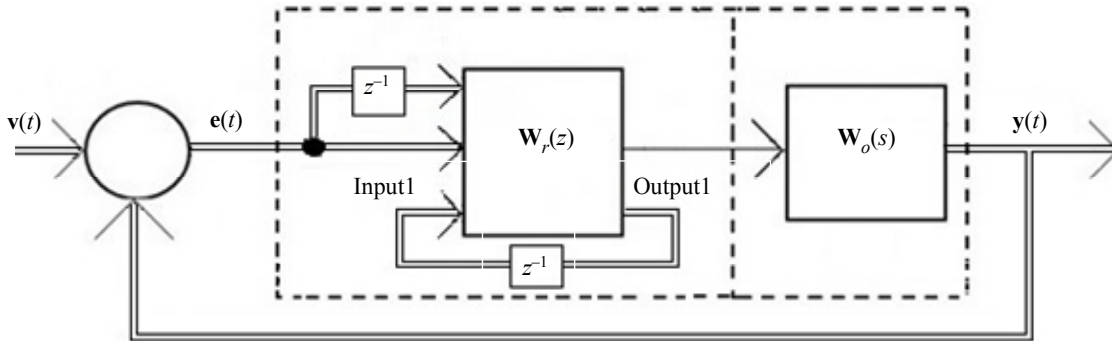


Рис. 10. САУ с преобразованным регулятором
 Fig. 10. Automatic control system with converted controller

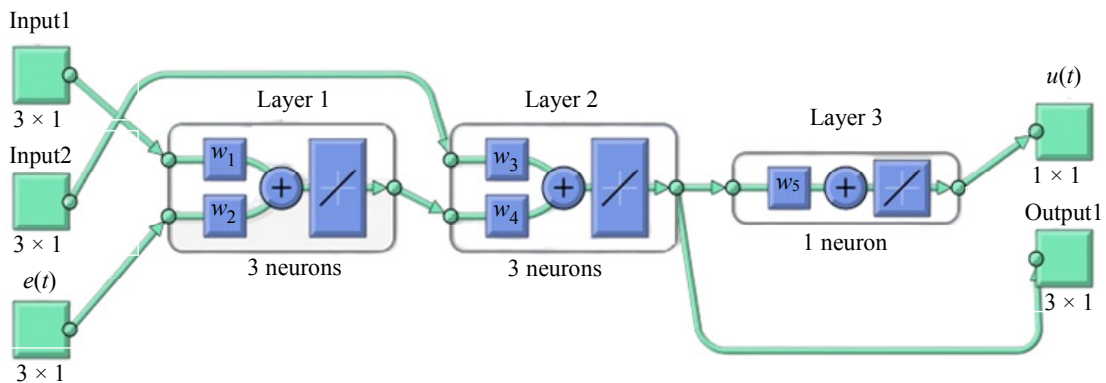


Рис. 11. Нейросетевой регулятор, полученный из преобразованного дискретного регулятора
 Fig. 11. A neural network controller derived from a converted discrete controller

инициализации весовых коэффициентов детерминированным способом. На рис. 9 представлена преобразованная структурная схема дискретного регулятора без обратных связей.

Обратные связи были перенесены за пределы регулятора и САУ может быть представлена в следующем виде (рис. 10).

Так как теперь имеем дело с преобразованной структурой регулятора необходимо повторить *четвертый шаг* и преобразовать структурный вид регулятора в нейросетевой. Для этого также воспользуемся преобразованиями, указанными в табл. 1 и получим следующий нейросетевой вид регулятора (рис. 11).

Снова попытаемся обучить данный нейросетевой регулятор. Обучение осуществляем по алгоритму «Левенберга–Марквардта» (Levenberg–Marquardt method) [27], [28], хорошо себя зарекомендовавшему как алгоритм с наибольшей скоростью сходимости и в связи с этим довольно часто применяемому в современных исследованиях [29], [30]. Обучающая выборка сформирована из работы дискретного регулятора, представленного на рис. 8. Так как переходные процессы на выходе системы при использовании нейросетевого регулятора (рис. 11) и преобразованного дискретного регулятора (рис. 9) идентичны, то и обучения такого нейросетевого регулятора не требуется и не происходит, в отличие от предыдущего случая (для нейросетевого регулятора, представленного на рис. 7, и дискретного регулятора на рис. 6), при котором обучение происходило за несколько шагов и полученный «обученный» нейросетевой регулятор не справлялся с управлением системой. Отсюда можем сделать вывод, что структурные преобразования дискретного

регулятора с выводом обратных связей за его пределы позволяют перейти к сети прямого распространения вместо рекуррентной сети. В свою очередь, это дает возможность избежать ошибок при обучении нейросетевого регулятора в случае инициализации весовых коэффициентов детерминированным способом.

На *пятом шаге* в первом и втором слоях заменим функции активации в полученном нейросетевом регуляторе с линейных на нелинейные. Здесь использовалась функция «гиперболический тангенс». Этот выбор связан с удобством нормирования весовых коэффициентов и с последующим обучением данного нейросетевого регулятора. Нормирование весовых коэффициентов необходимо для их инициализации таким образом, чтобы на начальном этапе обучения нейросетевого регулятора обеспечивались устойчивые переходные процессы на выходе САУ для малых значений желаемого перемещения тележки и начальных углов перевернутых маятников. Преобразованный нейросетевой регулятор представлен на рис. 12.

Нормированные весовые коэффициенты получены при помощи уменьшения значений, поступающих на вход нелинейной функции активации, в 1000 раз, и затем (после того как сигнал прошел функцию активации) необходимо увеличить сигнал также в 1000 раз. Это дает возможность привести работу нелинейной функции активации «гиперболический тангенс» к характеру работы линейной функции, а значит, позволит удержать полученную САУ в устойчивом положении еще до стадии обучения нейросетевого регулятора. Таким образом, после нормирования получены следующие весовые коэффициенты:




Рис. 12. Нейросетевая реализация преобразованного регулятора

Fig. 12. Neural network implementation of the transformed controller

$$W_1 = \begin{pmatrix} 3.4 & 0 & 0 \\ 0 & -3.2 & 0 \\ 0 & 0 & -0.007 \end{pmatrix};$$

$$W_2 = \begin{pmatrix} 0.9324 & 0 & 0 \\ 0 & 0.9324 & 0 \\ 0 & 0 & 0.9324 \end{pmatrix};$$

$$W_3 = \begin{pmatrix} -3.507 & 0 & 0 \\ 0 & 3.278 & 0 \\ 0 & 0 & 0.007 \end{pmatrix};$$

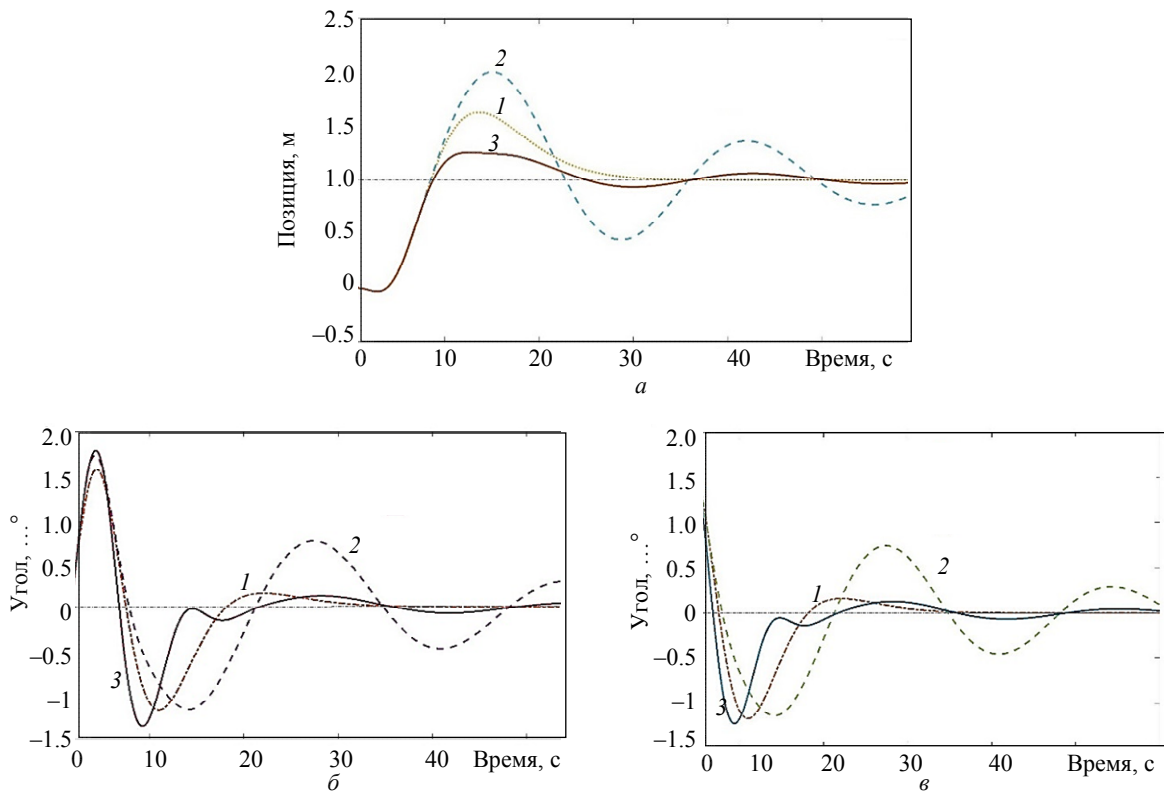
$$W_4 = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}, W_5 = \begin{pmatrix} 1000 \\ 1000 \\ 1000 \end{pmatrix}^T.$$

На *шестом шаге* применим процедуру обучения для преобразованного нейросетевого регулятора. Обучение будем проводить методом «обучения с учителем». В качестве эталонной выборки согласно алгоритму синтеза из [8] необходимо использовать непрерывный регулятор 2, так как

он лучше справляется с управлением моделью объекта, чем дискретный регулятор.

Таким образом, здесь был продемонстрирован алгоритм синтеза нейросетевого регулятора. Особенность данного алгоритма заключается в детерминированном подходе к выбору архитектуры и инициализации весовых коэффициентов нейронной сети. Информация об архитектуре и начальных весовых коэффициентах нейронной сети вычисляется на основании знания об изначальном регуляторе. В данном примере изначальный регулятор был синтезирован модальным методом, использующим полиномиальное матричное разложение. Особое внимание уделено вопросу структурных преобразований нейрорегуляторов с целью обучения рекуррентных нейронных сетей. В следующем разделе продемонстрируем переходные процессы на выходе системы и сравним эффективность работы непрерывного 2, дискретного 3 и нейросетевого регуляторов.

3. Моделирование и обсуждение полученных результатов. Здесь приведены графики переходных процессов – реакции на единичное ступенчатое воздействие.



1 – непрерывный регулятор; 2 – дискретный регулятор; 3 – нейрорегулятор

Рис. 13. Переходные процессы для системы автоматического управления с непрерывным, дискретными и нейрорегуляторами (а – для выхода системы, соответствующему положению тележки; б – для выхода системы, соответствующему углу первого маятника)

Fig. 13. Transients for automatic control systems with continuous, discrete and neuro regulators (а – for the exit of the system corresponding to the position of the cart; б – for the exit of the system corresponding to the angle of the first pendulum; в – for the exit of the system corresponding to the angle of the second pendulum)

пенчатое воздействие. Сравниваются САУ, использующие:

– изначальный непрерывный регулятор 2, полученный модальным методом с полиномиальным матричным разложением системы;

– дискретный регулятор 3, который был получен из непрерывного методом дискретизации (*c2d* – MatLab);

– преобразованный нейросетевой регулятор (рис. 12), архитектура и начальные весовые коэффициенты которого были получены исходя из сведений о дискретном регуляторе 3. Для проведения экспериментов использовались пакет прикладных программ для технических вычислений MatLab R2021a и система имитационного блочного моделирования динамических систем Simulink ver. 10.3 (R2021a). Переходные процессы на выходе САУ продемонстрированы на рис. 13 для всех трех выходов системы x , θ_1 , θ_2 .

В качестве заданий на вход системы подавались: $\bar{x} = 1$ м, $\bar{\theta}_1 = \bar{\theta}_2 = 0^\circ$.

Как видно из рис. 13, применение обученного нейросетевого регулятора 3 улучшило динамику системы (перерегулирование, время переходного процесса и его колебательность уменьшилась) по сравнению с переходными процессами САУ при использовании дискретного 2 и непрерывного 1 регуляторов. Обучение происходило с постепенным расширением области возможного задания на перемещение тележки. В результате САУ (рис. 4) устойчива и показывает идентичные результаты, если задание на перемещение тележки

лежит в пределах $[-1.3; 1.3]$ м. Для расширения границ работоспособности нейрорегулятора по заданию на перемещение тележки необходимо дополнительное обучение преобразованного нейросетевого регулятора.

Обсуждение результатов. В настоящей статье продемонстрирован алгоритм синтеза нейросетевого регулятора. К особенностям данного алгоритма относятся определение структуры нейронной сети и детерминированный способ инициализации ее весовых коэффициентов. Это позволяет начать обучение регулятора с устойчивого для всей системы состояния, однако при использовании рекуррентных нейронных сетей была выявлена особенность их обучения, которая негативно сказывалась на их возможности управлять САУ. Предложены некоторые структурные преобразования, позволяющие перейти к нейронной сети прямого распространения. При этом проблем с обучением данной нейронной сети не возникает. Затем архитектура полученного нейросетевого регулятора усложняется и проводится обучение на выборке, полученной при работе непрерывного регулятора. Обучение проводится с постепенным увеличением диапазона возможного изменения желаемого перемещения тележки. Благодаря введенным в нейросетевой регулятор нелинейностям типа «гиперболический тангенс» он справляется с управлением моделью объекта лучше по сравнению с дискретным и непрерывным регуляторами. В дальнейшем использование нейросетевого регулятора позволит учитывать также нелинейный характер модели объекта.

Список литературы

1. Омар С., Халид М., Юсоф Р. Нейроуправление и его приложения / пер. Н. В. Батина. М.: ИПРЖР, 2000. С. 121–132.
2. Нейросетевой регулятор для двухмассового упругого электромеханического объекта / В. В. Путов, А. В. Путов, М. М. Копычев, К. В. Игнатьев // Междунар. конф. по мягким вычислениям и измерениям. СПбГЭТУ «ЛЭТИ», 2015. Т. 1. С. 344–347.
3. Белов А. М., Белов М. П. Применение нейронных сетей в электроприводных системах насосных агрегатов // Междунар. конф. по мягким вычислениям и измерениям. СПбГЭТУ «ЛЭТИ», 2022. Т. 1. С. 91–94.
4. Сагдатуллин А. М. Методы, модели и алгоритмы повышения эффективности процессов добычи и транспортировки нефти и построения систем управления на основе нейросетевых и многомерных логических регуляторов с дискретными: дис. ... д-ра техн. наук: 2.3.3. Казань, 2022. 277 с.
5. Кабирова А. Н. Методы и комплексы программ построения нейросетевых моделей регуляторов для управления динамическим объектом: дис. ... канд. техн. наук: 05.13.18. Казань, 2017. 130 с.
6. Бурнаев Е. В., Ерофеев П. Д. Влияние инициализации параметров на время обучения и точность нелинейной регрессионной модели // Информационные процессы. 2015. Т. 15, № 3. С. 279–297.
7. Voevoda A. A., Shipagin V. I. Algorithm for the synthesis of a neural network controller for a multi-channel system // 2022 IEEE 23rd Intern. Conf. of Young Professionals in Electron Devices and Materials (EDM). Novosibirsk: IEEE, 2022. P. 605–610. doi: 10.1109/EDM55285.2022.9855047.
8. Воевода А. А., Шипагин В. И. Синтез нейросетевого регулятора управления нелинейной моделью перевернутого маятника на тележке // Науч. вестн. НГТУ. 2020. № 2–3 (79). С. 25–36. doi: 10.17212/1814-1196-2020-2-3-25-36.
9. Kailath T. Linear Systems. New Jersey, Prentice Hall: Englewood Cliffs, 1980. P. 103.
10. Филюшов В. Ю. Полиномиальный метод синтеза регуляторов для многоканальных объектов с неквадратной матричной передаточной функцией: дис. ... канд. техн. наук: 2.3.1. СПб., 2022. 177 с.

11. Шипагин В. И. Различные подходы к решению задачи перевернутого маятника // Сб. науч. тр. Новосибирского гос. техн. ун-та. 2019. № 2(95). С. 18–27. doi: 10.17212/2307-6879-2019-2-18-27. EDN SLPUPQ.
12. Воевода А. А., Шоба Е. В. О модели перевернутого маятника // Сб. науч. тр. НГТУ. 2012. № 1 (67). С. 3–14.
13. Гайдук А. Р., Беляев В. Е., Пьявченко Т. А. Теория автоматического управления в примерах и задачах с решениями в MatLab: учебник. 2-е изд., испр. СПб.: Лань, 2011. 464 с.
14. Bishop R. H. Modern control systems analysis and design using MatLab. New York: Massachusetts, 2006. 160 p.
15. Chen C. T. Linear system theory and design. 2nd ed. New York: Oxford, 1999. 334 p.
16. Doyle J. C., Francis B., Tannenbaum A. Feedback control. London: Macmillan Publishing, 1990. 198 p.
17. Spong M. W., Hutchinson S., Vidyasagar M. Robot modelling and control. John Willey and Sons inc., 2005. 496 p.
18. Соловьев А. М., Семенов М. Е., Мелешенко П. А. Стабилизация систем перевернутых маятников в условиях упругих связей // Сб. тр. IV междунар. конф. ИТНТ. Самара: Новая техника, 2018. С. 1617–1623.
19. Воевода А. А., Шипагин В. И. Об управляемости и наблюдаемости многоканальных САУ при синтезе модальным методом с использованием полиномиального матричного разложения объекта и регулятора // Безопасность цифровых технологий. 2022. № 3 (106). С. 26–48. doi: 10.17212/2782-2230-2022-3-26-48.
20. Pascanu R., Mikolov T., Bengio Y. On the difficulty of training recurrent neural networks // ICML. 2013. No. 28. P. 1310–1318. doi: 10.48550/arXiv.1211.5063.
21. Haykin S. Neural networks and learning machines. 3rd ed. Pearson Education, 2009. 937 p.
22. Dasgupta B., Siegelmann H., Sontag E. D. On the complexity of training neural networks with continuous activation functions // IEEE Transactions on Neural Networks. 1995. Vol. 6, no. 6. P. 1490–1504.
23. Graves A. Supervised sequence labelling // Supervised Sequence Labelling with Recurrent Neural Networks. Berlin, Heidelberg: Springer, 2012. URL: <https://www.cs.toronto.edu/~graves/preprint.pdf>. (дата обращения 21.10.2022).
24. Schrauwen B., Verstraeten D., Campenhout J. V. An overview of reservoir computing theory, applications and implementations / Proc. of the 15th European Symp. on Artificial Neural Network. Belgium, 2007. P. 471–482.
25. Воевода А. А., Шипагин В. И. Расчет регулятора для многоканального объекта с нестационарными параметрами, содержащего звенья запаздывания // Системы анализа и обработки данных. 2022. № 1(85). С. 7–24. doi: 10.17212/2782-2001-2022-1-7-24.
26. Дзюба Д. А., Чернодуб А. Н. Обзор методов нейрорегулирования // Проблемы программирования. 2011. № 2. С. 79–94.
27. Levenberg K. A method for the solution of certain nonlinear problems in least squares // Quarterly of Appl. Math. 1944. No. 2. P. 164–168.
28. Marquardt D. An algorithm for least squares estimation of nonlinear parameters // SIAM J. of Appl. Math. 1963. No. 11. P. 431–441.
29. Комиссаров Ю. А., Дам К. Ш. Использование алгоритма Левенберга Марквардта для нахождения параметров бинарных пар в уравнениях Вильсона, НРТЛ и ЮНИКВАК // Вестн. АГТУ. Сер.: Управление, вычислительная техника и информатика. 2011. № 2. С. 37–42.
30. Бурцев А. Г., Жангабулов Т. А. Сравнение различных численных методов для решения задачи ультразвукового позиционирования подвижного робота в закрытом пространстве // Инженерный Вестн. Дона. 2016. № 2 (41). С. 32–42. URL: http://www.ivdon.ru/uploads/article/pdf/IVD_25_Burtsev_Zhangabulov.pdf_0262cc099c.pdf (дата обращения 29.10.2022).

Информация об авторах

Воевода Александр Александрович – д-р техн. наук, профессор, профессор кафедры автоматизации Новосибирского государственного технического университета, ул. Немировича-Данченко, д. 136, Новосибирск, Россия.

E-mail: voevoda@corp.nstu.ru

<http://orcid.org/0000-0002-1604-2796>

Шипагин Виктор Игоревич – аспирант Новосибирского государственного технического университета, ул. Немировича-Данченко, д. 136, Новосибирск, Россия.

E-mail: shipagin@mail.ru

<http://orcid.org/0000-0003-1292-7543>

References

1. Omatu S., Halid M., Jusof R. Nejroupravlenie i ego prilozhenija / per. N. V. Batina. M.: IPRZhR, 2000. S. 121–132. (In Russ.).
2. Nejrosetevoj reguljator dlja dvuhmassovogo uprugogo jelektromehaničeskogo ob#ekta / V. V. Putov, A. V. Putov, M. M. Kopychev, K. V. Ignat'ev // Mezhdunar. konf. po mjagkim vychislenijam i izmerenijam. SPbGJeTU «LJeTI», 2015. T. 1. S. 344–347. (In Russ.).
3. Belov A. M., Belov M. P. Primenenie nejronnyh setej v jelektroprivodnyh sistemah nasosnyh agregatov

// Mezhdunar. konf. po mjagkim vychislenijam i izmernenijam. SPbGJeTU «LJeTI», 2022. T. 1. S. 91–94. (In Russ.).

4. Sagdatullin A. M. Metody, modeli i algoritmy povyshenija jeffektivnosti processov dobychi i transportirovki nefti i postroenija sistem upravlenija na osnove nejrosetevykh i mnogomernykh logicheskikh reguljatorov s diskretnymi: dis. ... d-ra tehn. nauk: 2.3.3. Kazan', 2022. 277 s. (In Russ.).

5. Kabirova A. N. Metody i komplekсы programm postroenija nejrosetevykh modelej reguljatorov dlja upravlenija dinamicheskim ob#ektom: dis. ... kand. tehn. nauk: 05.13.18. Kazan', 2017. 130 s. (In Russ.).

6. Burnaev E. V., Erofeev P. D. Vlijanie inicializacii parametrov na vremja obuchenija i tochnost' nelinejnoj regressionnoj modeli // Inform. processy. 2015. T. 15, № 3. S. 279–297. (In Russ.).

7. Voevoda A. A., Shipagin V. I. Algorithm for the synthesis of a neural network controller for a multi-channel system // 2022 IEEE 23rd Intern. Conf. of Young Professionals in Electron Devices and Materials (EDM). Novosibirsk: IEEE, 2022. P. 605–610. doi: 10.1109/EDM55285.2022.9855047.

8. Voevoda A. A., Shipagin V. I. Sintez nejrosetevogo reguljatora upravlenija nelinejnoj model'ju perevernutogo majatnika na telezhke // Nauch. vestn. NGTU. 2020. № 2–3 (79). S. 25–36. doi: 10.17212/1814-1196-2020-2-3-25-36. (In Russ.).

9. Kailath T. Linear Systems. New Jersey, Prentice Hall: Englewood Cliffs, 1980. P. 103. (In Russ.).

10. Filjushov V. Ju. Polinomial'nyj metod sinteza reguljatorov dlja mnogokanal'nykh ob'ektov s nekvadratnoj matrichnoj peredatochnoj funkciej: dis. ... kand. tehn. nauk: 2.3.1. SPb., 2022. 177 s. (In Russ.).

11. Shipagin V. I. Razlichnye podhody k resheniju zadachi perevernutogo majatnika // Sb. nauch. tr. Novosibirskogo gos. tehn. un-ta. 2019. № 2(95). S. 18–27. doi: 10.17212/2307-6879-2019-2-18-27. EDN SLPUPQ. (In Russ.).

12. Voevoda A. A., Shoba E. V. O modeli perevernutogo majatnika // Sb. nauch. tr. NGTU. 2012. № 1 (67). S. 3–14. (In Russ.).

13. Gajduk A. R., Beljaev V. E., P'javchenko T. A. Teorija avtomaticheskogo upravlenija v primerah i zadachah s reshenijami v MatLab: uchebnik. 2-e izd., ispr. SPb.: Lan', 2011. 464 s. (In Russ.).

14. Bishop R. H. Modern control systems analysis and design using MatLab. New York: Massachusetts, 2006. 160 p.

15. Chen C. T. Linear system theory and design. 2nd ed. New York: Oxford, 1999. 334 p.

16. Doyle J. C., Francis B., Tannenbaum A. Feedback control. London: Macmillan Publishing, 1990. 198 p.

17. Spong M. W., Hutchinson S., Vidyasagar M. Robot modelling and control. John Willey and Sons inc., 2005. 496 p.

18. Solov'ev A. M., Semenov M. E., Meleshenko P. A. Stabilizacija sistem perevernutykh majatnikov v uslovijah

uprugih svjazej // Sb. tr. IV mezhdunar. konf. ITNT. Samara: Novaja tehnika, 2018. S. 1617–1623. (In Russ.).

19. Voevoda A. A., Shipagin V. I. Ob upravljaemosti i nabljudaeemosti mnogokanal'nykh SAU pri sinteze modal'nym metodom s ispol'zovaniem polinomial'nogo matrichnogo razlozhenija ob#ekta i reguljatora // Bezopasnost' cifrovyykh tehnologij. 2022. № 3 (106). S. 26–48. doi: 10.17212/2782-2230-2022-3-26-48. (In Russ.).

20. Pascanu R., Mikolov T., Bengio Y. On the difficulty of training recurrent neural networks // ICML. 2013. No. 28. P. 1310–1318. doi: 10.48550/arXiv.1211.5063.

21. Haykin, S. Neural networks and learning machines. 3rd ed. Pearson Education, 2009. 937 p.

22. Dasgupta B., Siegelmann H., Sontag E. D. On the complexity of training neural networks with continuous activation functions // IEEE Transactions on Neural Networks. 1995. Vol. 6, no. 6. P. 1490–1504.

23. Graves A. Supervised sequence labelling // Supervised Sequence Labelling with Recurrent Neural Networks. Berlin, Heidelberg: Springer, 2012. URL: <https://www.cs.toronto.edu/~graves/preprint.pdf>. (data obrashcheniya 21.10.2022).

24. Schrauwen B., Verstraeten D., Campenhout J. V. An overview of reservoir computing theory, applications and implementations / Proc. of the 15th European Symp. on Artificial Neural Network. Belgium, 2007. P. 471–482.

25. Voevoda A. A., Shipagin V. I. Raschet reguljatora dlja mnogokanal'nogo ob'ekta s nestacionarnymi parametrami, sodержashhego zven'ja zapazdyvanija // Sistemy analiza i obrabotki dannykh. 2022. № 1(85). S. 7–24. doi: 10.17212/2782-2001-2022-1-7-24. (In Russ.).

26. Dzijuba D. A., Chernodub A. N. Obzor metodov nejroupravlenija // Problemy programirovanija. 2011. № 2. S. 79–94. (In Russ.).

27. Levenberg K. A method for the solution of certain nonlinear problems in least squares // Quarterly of Appl. Math. 1944. № 2. P. 164–168.

28. Marquardt D. An algorithm for least squares estimation of nonlinear parameters // SIAM J. of Appl. Mathematics. 1963. No. 11. P. 431–441.

29. Komissarov Ju. A., Dam K. Sh. Ispol'zovanie algoritma Levenberga–Markvardta dlja nahozhdenija parametrov binarnykh par v uravnenijah Vil'sona, NRTL i JUNKVAK // Vestn. AGTU. Ser.: Upravlenie, vychislitel'naja tehnika i informatika. 2011. № 2. S. 37–42. (In Russ.).

30. Burcev A. G., Zhangabulov T. A. Sravnenie razlichnykh chislennykh metodov dlja reshenija zadachi ul'trazvukovogo pozicionirovanija podvizhnogo robota v zakrytom prostranstve // Inzhenernyj Vestn. Dona. 2016. № 2 (41). S. 32–42. URL: http://www.ivdon.ru/uploads/article/pdf/IVD_25_Burtsev_Zhangabulov.pdf_0262cc099c.pdf (data obrashheniya 29.10.2022). (In Russ.).

Information about the authors

Aleksandr A. Voevoda – Dr Sci. (Eng.), Professor of Novosibirsk State Technical University (Department of Automation), Nemirovich-Danchenko str., 136, Novosibirsk, 630087, Russia.

E-mail: voevoda@corp.nstu.ru

<http://orcid.org/0000-0002-1604-2796>

Victor I. Shipagin – postgraduate student of Novosibirsk State Technical University, Nemirovich-Danchenko str., 136, Novosibirsk, 630087, Russia.

E-mail: shipagin@mail.ru

<http://orcid.org/0000-0003-1292-7543>

Статья поступила в редакцию 11.11.2022; принята к публикации после рецензирования 23.11.2022; опубликована онлайн 30.01.2023.

Submitted 11.11.2022; accepted 23.11.2022; published online 30.01.2023.
