

АВТОМАТИЗАЦИЯ И УПРАВЛЕНИЕ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ И ПРОИЗВОДСТВАМИ

DOI: 10.21821/2309-5180-2025-17-4-599-612

EDN URSIRN

SYNTHESIS AND MODELING OF THE ADAPTIVE CONTROL SYSTEM ELECTRIC DRIVE WITH REFERENCE MODEL NEURAL REGULATOR

V. V. Saharov, A. A. Chertkov, Ya. N. Kask,

Admiral Makarov State University of Maritime and Inland Shipping,
St. Petersburg, Russian Federation

The purpose of this work is to implement intelligent algorithms for the synthesis of control systems for electric drives of power supply systems at water transport facilities using artificial neural networks. The use of such intelligent algorithms will make it possible to carry out in practice the digital transformation of hardware units of regulators (controllers) in control systems for various objects, including electric drives, into mathematical algorithms based on neural network controllers. Such controllers, for example, those using a reference model, are more preferable when controlling nonlinear objects, since the neural networks on which they are based are nonlinear. In view of this, the scope of their application has been significantly expanded in the further development of methods for computer monitoring and parametric identification of ship and shore power supply management models, as well as the analysis and forecasting of energy efficiency indicators of their operating modes. The procedure for synthesizing a neural network regulator built on the basis of a reference model to stabilize the angular velocity of a DC motor is considered, aiming to compensate for oscillations occurring in the drive control loop. Using a PID tuner, the parameters of the PID controller were determined, significantly affecting control quality and allowing it, together with a typical first-order astatic link, to perform the function of a reference regulator for training the neural network controller. It is shown that the selected parameters of the neural model of the controlled object and the neural network reference regulator made it possible to significantly improve the quality of the transient process and eliminate oscillations in the DC motor drive control. The indicators and characteristics of the training quality of the neural network regulator and the neural model of the object with the selected training parameters are presented. An algorithm for training the neural model of the controlled object and the neural network regulator based on the dynamic nature of the backpropagation of error deviations of output signal values from reference ones in a multilayer neural network is proposed, with the purpose of correction through introducing adjustments to the values of synaptic weight coefficients. The algorithm can be applied in control systems for electric drives of unmanned objects, including aircraft, waterborne, and land-based systems in inland water transport.

Key words: algorithm, parametric identification, consumption characteristics, neural networks, network technologies, approximation, parameter estimation.

For citation:

Saharov, Vladimir V., A. A. Chertkov and Ya. N. Kask. "Synthesis and modeling of the electric drive control system based on the reference model of the neural regulator." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 17.4 (2025): 599–612. DOI: 10.21821/2309-5180-2025-17-4-599-612.

УДК. 621.398.04

СИНТЕЗ И МОДЕЛИРОВАНИЕ СИСТЕМЫ АДАПТИВНОГО УПРАВЛЕНИЯ ЭЛЕКТРОПРИВОДОМ С ЭТАЛОННОЙ МОДЕЛЬЮ НЕЙРОННОГО РЕГУЛЯТОРА

В. В. Сахаров, А. А. Чертков, Я. Н. Каск,

ФГБОУ ВО «ГУМРФ имени адмирала С. О. Макарова»,
Санкт-Петербург, Российская Федерация

Целью работы является реализация интеллектуальных алгоритмов синтеза систем управления электроприводами систем энергоснабжения на объектах водного транспорта с использованием искусственных нейронных сетей. Использование подобных интеллектуальных алгоритмов позволит на практике осуществлять цифровую трансформацию аппаратных узлов регуляторов (контроллеров) в системах управления различными объектами, в том числе электроприводами, в математические алгоритмы, базирующиеся на нейросетевых контроллерах. Такие контроллеры, например, с использованием эталонной модели, являются более предпочтительными при управлении нелинейными объектами, поскольку нейросети, на которых они базируются, нелинейны. В связи с этим существенно расширена область их применения в дальнейшем развитии методов компьютерного мониторинга и параметрической идентификации моделей судовых и береговых объектов управления энергоснабжением, а также анализа и прогнозирования показателей энергоэффективности их режимов работы. Рассмотрена процедура синтеза нейросетевого регулятора, построенного на основе эталонной модели, для стабилизации угловой скорости вращения двигателя постоянного тока с целью компенсации колебаний, возникающих в контуре управления приводом. С использованием PID-тюнера определены параметры PID-регулятора, существенно влияющие на качество управления и позволившие ему в составе с типовым астатическим звеном первого порядка выполнять функции эталонного регулятора для обучения нейросетевого регулятора. Показано, что выбранные параметры нейронной модели объекта управления и нейросетевого эталонного регулятора позволили существенно улучшить показатели качества переходного процесса и устранить колебания в приводе управления двигателя постоянного тока. Приведены показатели и характеристики качества обучения нейросетевого регулятора и нейронной модели объекта при выбранных параметрах обучения. Предложен алгоритм обучения нейронной модели управляемого объекта и нейросетевого регулятора модели, базирующийся на динамическом характере обратного распространения ошибки отклонений значений выходных сигналов от эталонных в многослойной нейронной сети с целью ее коррекции за счет введения поправок в значения весовых коэффициентов синаптических связей. Алгоритм может быть применим в системах управления электроприводами безкипажных объектов, как летательных, так водного и наземного базирования, на внутреннем водном транспорте.

Ключевые слова: алгоритм, параметрическая идентификация, расходная характеристика, нейронные сети, сетевые технологии, аппроксимация, оценка параметров.

Для цитирования:

Сахаров В. В. Синтез и моделирование системы управления электроприводом на основе эталонной модели нейронного регулятора / В. В. Сахаров, А. А. Чертков, Я. Н. Каск // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2025. — Т. 17. — № 4. — С. 599–612. DOI: 10.21821/2309-5180-2025-17-4-599-612. — EDN URSIRN.

Введение (Introduction)

В условиях цифровой трансформации открываются новые возможности для удовлетворения возрастающих требований к характеристикам электроэнергетических систем и объектов управления на водном транспорте, что позволяет обеспечить повышение надежности их работы за счет замены аппаратных средств этих систем интеллектуальными (математическими) алгоритмами с использованием высокотехнологичных узлов специализированной вычислительной техники, например, нейропроцессорами. Использование компьютерных технологий и роботизированных систем на основе искусственного интеллекта в управлении энергетическими системами объектов морского и речного флота является важнейшей задачей цифровизации в судостроении и на предприятиях отрасли [1]–[3]. Цифровизация отрасли водного транспорта предполагает максимальное использование систем искусственного интеллекта (нейропроцессоров) не только в технологии проектно-конструкторских работ и производстве конечного продукта, в частности, электропривода [4], но также в мониторинге и диагностировании его параметров, не подлежащих измерениям с применением аппаратных средств в период штатной эксплуатации.

В последнее десятилетие существенно повысился интерес к применению искусственных нейронных сетей для решения задач обработки, распознавания, идентификации, а также оптимального управления с применением нейросетевых регуляторов. Это объясняется стремительным развитием технологий искусственного интеллекта и нейропроцессоров, обеспечивающих возможность управления сложными нелинейными объектами, так как используемые ими нейросети нелинейны по своей природе. Кроме того, нейросетевые методы управления объектами, в отличие

от классических методов, в результате их способности к обучению и самообучению применимы для адаптивного управления объектами при вариации их параметров и условиях эксплуатации. В частности, в электроэнергетике, адаптивное управление на основе нейросетевого регулятора позволяет решать актуальную задачу обеспечения робастной устойчивости управления электроприводами, что позволяет в точности отслеживать сигнал задатчика и компенсировать колебания, возникающие в контуре управления приводом [5].

Эффективность мониторинга, прогнозирования и оптимального управления приводами электроэнергетических систем с целью экономии энергоресурсов может быть повышена с применением искусственных нейронных сетей, моделирующих адаптируемые и обучаемые процессы распределенных мультипроцессорных систем, ассоциируемые с нейросетевыми процессами человеческого мозга [6], [7].

Нейросетевые процессы в синаптических связях многослойной сети между нейронами за счет массового параллелизма их работы значительно ускоряют обработку информации, обеспечивая вычисления с требуемой точностью. В отличие от известных технологических процессов они не программируются, а обучаются. Одной из известных структур нейросетевых регуляторов в составе инструментария NN Toolbox Simulink среды MATLAB является регулятор, использующий эталонную (reference) модель, в соответствии с которой с помощью нейронных сетей регулятора и объекта управления, а также набора данных для их обучения осуществляется настройка (по ошибке рассогласования) управляемого объекта, т. е. реализуется адаптивное управление. На основе результатов обучения и моделирования нейросетевых моделей регулятора и объекта получены ожидаемые характеристики качества переходного процесса на выходе системы [8], [9].

Методы и материалы (Methods and Materials)

Использование эталонной модели в регуляторах позволяет осуществлять самонастройку систем, в которых управление осуществляется посредством прямого адаптивного подхода, способных настраиваться автоматически. Определяющую роль в таких системах играют контуры адаптации или самонастройки по эталонной модели, от числа которых зависит размерность вектора переменных состояния, а также устойчивость, робастность и динамика замкнутой системы. Структура нейросети с эталонным регулятором и объектом управления приведена на рис. 1 [10].




Рис. 1. Структура нейросети с эталонным регулятором и объектом управления

Как видно из схемы, ее основу составляет эталонная модель, отклик (реакция) y_{mz} которой на входное (задающее) воздействие u_z в виде единичного ступенчатого сигнала в установившемся режиме в точности ему соответствует. Для формирования желаемого отклика y_{mz} используют модели типовых динамических звеньев первого или второго порядков, которые могут быть интегрированы с ПИД-регуляторами [10]. В этом случае для эффективной настройки объекта по эталону интегрированная нейросеть адаптивной системы должна включать нейросети регулятора и модели объекта с контурами их настройки с помощью обратных связей. В результате настройки

по ошибке рассогласования выходов объекта и эталона выполняется непрерывная коррекция параметров системы в ответ на изменения внешних и внутренних условий. Нейросетевая структура системы управления с эталонной моделью, построенная в среде моделирования SIMULINK MATLAB, представлена на рис. 2.




Рис. 2. Simulink-модель системы адаптивного управления объектом

Из данного рисунка видно, что Simulink-модель нейросетевой системы адаптивного управления содержит блок контроллера Model Reference Control и объект идентификации Plant Model, интегрированный в блоке Subsystem, имеющем входной In и выходной Out порты. Рассмотрим их состав и характеристики.

Модель нелинейного объекта управления (Plant Model). В качестве нелинейного объекта управления выберем электропривод двигателя постоянного тока (ДПТ) с независимым возбуждением. Синтез и моделирование электропривода требуют его математическую описания. Основой для построения математической модели ДПТ служит система дифференциальных уравнений (СДУ), которая адекватно описывает его переходные процессы. Кроме того, такой подход позволяет исследовать и статические режимы в виде установившихся процессов, при которых производные функций равны нулю. Для математического описания работы любого электропривода необходимо составить его электрическую схему замещения, из которой по законам Кирхгофа можно записать уравнения электрического равновесия контуров как подвижной, так и неподвижной частей электрической машины. Пример такой схемы замещения для привода ДПТ приведен на рис. 3.




Рис. 3. Электрическая схема замещения ДПТ

Математическая модель электрической машины (ЭМ) любого типа состоит из уравнений электрического равновесия всех контуров ЭМ и уравнения движения ротора.

Будем считать, что все параметры схемы замещения — постоянные величины, в том числе магнитный поток ψ , замыкающийся между разноименными полюсами машины (поток полюсов для ДПТ независимого возбуждения). Уравнение равновесия по второму закону Кирхгофа:

$$U_{\text{я}} = e_{\text{я}} + i_{\text{я}} R_{\text{я}} + L_{\text{я}} \frac{di_{\text{я}}}{dt} = e_{\text{я}} + i_{\text{я}} R_{\text{я}} + T_{\text{я}} R_{\text{я}} \frac{di_{\text{я}}}{dt},$$

где $U_{\text{я}}$ — напряжение источника питания, подаваемое на электрическую часть якоря двигателя;

$e_{\text{я}} = \psi \cdot \omega$ — ЭДС, наводимая в обмотке якоря при пересечении проводников потока ψ , создаваемого неподвижными полюсами;

$i_{\text{я}}$ — электрический ток в якорной цепи;

$R_{\text{я}}$ — полное электрическое сопротивление якорной цепи, включая сопротивление дополнительных полюсов и щеток;

$L_{\text{я}}$ — индуктивность якорной цепи;

$T_{\text{я}} = L_{\text{я}}/R_{\text{я}}$ — постоянная времени якорной цепи;

Уравнение движения для механической части:

$$M_e - M_c = T_j \frac{d\omega}{dt},$$

где $M_e = \psi \cdot i_{\text{я}}$, M_c — электромагнитный и статический моменты;

ω — скорость вращения якоря;

T_j — инерционная постоянная времени двигателя.

В канонической форме Коши математическая модель в пространстве состояний имеет вид:

$$\frac{di_{\text{я}}}{dt} = (U_{\text{я}} - e_{\text{я}} - i_{\text{я}} R_{\text{я}}) \frac{1}{L_{\text{я}}};$$

$$\frac{d\omega}{dt} = (m - m_c) \frac{1}{T_j}.$$

Записав полученные уравнения в операторной форме, передаточные функции между напряжением, током, моментом и скоростью будут иметь следующий вид:

$$W_i(s) = \frac{I_{\text{я}}(s)}{U_{\text{я}}(s) - e_{\text{я}}(s)} = \frac{1}{T_{\text{я}} + 1};$$

$$W_{\omega} = \frac{\omega(s)}{M_e(s) - M_c(s)} = \frac{1}{T_j s}.$$

Эти передаточные функции положим в основу структурной схемы модели ДПТ, представленной на рис. 4.




Рис. 4. Структурная схема модели ДПТ

Зададимся следующими параметрами модели ДПТ: $R_{\text{я}} = 0,107$ Ом, $T_{\text{я}} = 0,034$ с, $T_j = 0,72$ с. Структура модели ДПТ с указанными параметрами в Simulink MATLAB будет иметь вид, представленный на рис. 5.




Рис. 5. Simulink-модель ДПТ

Поскольку целью работы является синтез нейросетевого регулятора, назначением которого является подавление колебаний, возникающих в контуре управления объекта, и обеспечение требуемого уровня выходного сигнала, в контур объекта управления (обратной связи) внесен функциональный блок Fcn 2, который придает переходному процессу на выходе объекта колебательный характер (рис. 6).




Рис. 6. Переходный процесс на выходе Simulink-модели ДПТ

Как видно из характеристики переходного процесса на рис. 6, величина перерегулирования, составляющая 32 %, превышает принятое допустимое значение 10 %.

Регулятор на основе эталонной модели. При управлении на основе эталонной модели регулятор — это нейронная сеть, которая обучена управлять процессом так, чтобы он отслеживал поведение эталонного процесса. При этом модель управляемого процесса активно используется при настройке параметров самого регулятора. Эталонная Simulink-модель нейронного регулятора представлена на рис. 7.




Рис. 7. Simulink-модель эталонного нейросетевого регулятора с ПИД-контроллером

Регулятор на основе эталонной модели представляет собой типовое астатическое звено первого порядка, которое для получения желаемой характеристики переходного процесса (рис. 7) дополнено ПИД-регулятором, параметры которого (рис. 8) получены с помощью PID Tuner [12].

Controller Parameters		
	Tuned	Block
P	1.103	1
I	26.477	1
D	0	0
N	100	100
Performance and Robustness		
	Tuned	Block
Rise time	0.0815 seconds	3.17 seconds
Settling time	0.126 seconds	6.36 seconds
Overshoot	0.594 %	0 %
Peak	1.01	0.998
Gain margin	Inf dB @ NaN rad/s	Inf dB @ NaN rad/s
Phase margin	84.8 deg @ 24 rad/s	155 deg @ 4.47 rad/s
Closed-loop stability	Stable	Stable

Рис. 8. Параметры настройки ПИД-регулятора с помощью PID Tuner MATLAB

Характеристика переходного процесса эталонной модели регулятора с параметрами, приведенными на рис. 8, представлена на рис. 9.




Рис. 9. Желаемая переходная характеристика эталонной модели регулятора

Архитектура регулятора с эталонной моделью требует обучения нейронной сети управляемого процесса и нейронной сети регулятора. При этом обучение регулятора оказывается достаточно сложным, поскольку оно основано на динамическом варианте метода обратного распространения ошибки, так как нейронная сеть использует линии задержки.

Обучение нейронной сети с эталонным регулятором. Для того чтобы начать работу, необходимо активизировать блок Model Reference Controller (см. рис. 2) двойным щелчком левой кнопки мыши. Появится окно, показанное на рис. 10.




Рис. 10. Окно обучения нейронной сети регулятора

Особенность рассматриваемой системы управления заключается в том, что следует построить две нейронные сети: модели объекта управления и самого регулятора. Архитектуру нейрон-

ной сети регулятора (см. рис. 10), имеющую два слоя, можно описать профилем 2–13–1 (два входа, 13 нейронов скрытого слоя и один выход).

Следующим шагом является обучение модели объекта идентификации путем выбора кнопки **Plant Identification** в окне, показанном на рис. 10. При этом откроется окно **Plant Identification** (Объект идентификации), в котором устанавливаются выбранные параметры нейронной сети модели объекта управления (рис. 11). Линии задержки, используемые для формирования входов нейронных сетей, имеют такт дискретности, равный 0,05 с. Число циклов обучения задается параметром **Training Epochs**.




Рис. 11. Окно обучения нейронной сети модели объекта управления

Для запуска процесса обучения нейронной модели объекта идентификации следует создать набор обучающих данных. С этой целью выбирается кнопка **Generate Training Data**, после чего программа начинает генерировать данные для обучения контроллера. По окончании обучения в окне **Plant Input-Output Data** откроются графики (рис. 12).




Рис. 12. Сигналы входа и выхода нейронной модели объекта после обучения

После того как будут сгенерированы данные, необходимо подтвердить выполненную процедуру идентификации. Если построенные графики **Plant Input** и **Plant Output** удовлетворяют сге-

нерированным данным, то для подтверждения результатов идентификации (см. рис. 12), следует нажать кнопку **Accept Data** (*Принять данные*), в противном случае выбирается кнопка **Reject Data** (*Отвергнуть данные*) для ввода новых данных.

Следующим шагом является запуск кнопкой **Train Network** окна **Plant Identification** процесса обучения нейронной модели объекта нейроконтроллером. По окончании обучения его результаты можно увидеть, открыв графики **Performance** (рис. 13), **Training State** и **Regression**, которые создаются нажатием соответствующих кнопок в окне **Neural Network Training** (Nntraintool) — рис. 14. В том же окне приведена структура нейронной сети объекта идентификации с профилем 2–10–1 (два входа, 10 нейронов скрытого слоя и один выход).




Рис. 13. Характеристики производительности процесса обучения нейросети объекта




Рис. 14. Архитектура нейронной сети объекта идентификации

Если сходимость и точность характеристик производительности (см. рис. 13) соответствуют наилучшему значению, то результаты обучения сохраняются нажатием кнопки **Apply** или **OK** в окне **Plant Identification**.

Далее начинается настройка регулятора через интерфейс **Model Reference Control** (см. рис. 10) посредством подготовки данных обучения, для генерации которых необходимо нажать кнопку **Generate Training Data**. Если построенные графики (рис. 15) реакции и воздействия эталонной модели **Reference Model Output** соответствуют данным настройки, то нажатием кнопки **Accept Data** под графиками переходим к его обучению.




Рис. 15. Графики воздействия и реакции на нее эталонной модели нейронного регулятора

Полученные данные для обучения нейросетевого регулятора можно экспортировать в **Workspace** или в *m*-файл, воспользовавшись для этого кнопкой **Export Data**.

Далее нажатием кнопки **Train Controller** запускаем процесс обучения нейросетевого регулятора. После того как обучение будет окончено, графики выходов эталонной модели и объекта управления выводятся на экран (рис. 16). Результаты обучения можно посмотреть, открыв графики **Performance** (рис. 17), **Training State** и **Regression** — в окне (рис. 18) **Neural Network Training** (nntraintool), которые создаются нажатием соответствующих кнопок.




Рис. 16. Сигналы выходов эталонной модели и объекта управления




Рис. 17. График изменения средней квадратической ошибки слежения

Если точность слежения за эталонной моделью неудовлетворительна (см. рис. 17), то можно продолжить обучение регулятора с тем же набором данных, снова воспользовавшись кнопкой **Train Controller**. В противном случае можно повторить набор данных с помощью кнопки **Generate Data** или продолжить обучение с новыми весами, выбрав вкладку **Use Current Weights**. В случае соответствия ее наилучшему значению результаты обучения сохраняются нажатием кнопки **Apply** или **OK** в окне **Model Reference Control**.




Рис. 18. Структура нейронной сети контроллера и нейронной сети модели объекта управления

В окне **Neural Network Training (nntraintool)** также приведена структура нейронной сети контроллера и нейронной сети модели объекта управления (см. рис. 18) с обратными связями и заданными параметрами. Обучение регулятора занимает весьма значительное время, поскольку обучение использует динамический вариант метода обратного распространения ошибки [16].

Результаты (Results)

Для проверки результатов обучения регулятора возвращаемся к Simulink-модели системы управления (см. рис. 2) и выбрав опцию **Start** в меню **Simulation** запускаем моделирование. Реакция объекта (ДПТ), управляемого обученной нейросетью с эталонным регулятором, на единичное ступенчатое воздействие приведена на графиках (рис. 19).




Рис. 19. Реакция системы адаптивного управления с эталонной моделью на ступенчатое воздействие

Как видно из графиков, переходный процесс в обученной нейросети с эталонной моделью имеет монотонный характер и в установившемся режиме практически достигает уровня единичного входного воздействия, что свидетельствует о хорошем качестве нейросетевого регулятора. Из зависимостей (см. рис. 19) переходных процессов построенной модели системы адаптивного управления (с нейросетевым регулятором) и реакции автономной (без регулятора) модели управления того же ДПТ (см. рис. 6) следует, что системе адаптивного управления при одном и том же единичном воздействии удалось обеспечить получение следующих результатов:

- полностью подавить паразитные колебания на выходе системы, возникающие в контуре обратной связи ДПТ, обеспечивая монотонный характер переходного процесса;
- существенно повысить точность регулирования в установившемся режиме с погрешностью, не превышающей 5 %, повысив уровень выходного сигнала с 0,25 В до 0,95 В (практически в 4 раза);
- по показателю быстродействия на единичное воздействие система адаптивного управления полностью соответствует эталонной модели с ПИД-регулятором (см. рис. 9).

Обсуждение (Discussion)

Как показывает практика, моделирование систем управления по нелинейным моделям, описываемых нелинейными уравнениями, представляет собой более сложную задачу, чем моделирование линейных систем. Данное обстоятельство вынуждает обратиться к нейронным сетям, обладающим нелинейной природой для решения задач, связанных с нелинейными динамическими системами, которые позволяют существенно сократить объем вычислительных ресурсов, требуемых в задачах высокой размерности вектора переменных состояния.

Полученные результаты моделирования позволяют сделать вывод о том, что наличие контуров самонастройки в нейросетевой структуре регулятора и модели управления дают возможность реализовать адаптивное управление, в процессе которого выполняется непрерывная коррекция параметров системы управления в ответ на изменения сигналов ее обратных связей и внутренних состояний. Несмотря на значительные затраты времени, расходуемого на обучение, реализуемое в системе адаптивное управление существенно расширяет область применения нейросетевых регуляторов при управлении сложными и нелинейными объектами высокого порядка размерности.

Выводы (Summary)

На основе результатов синтеза системы адаптивного управления электроприводом с эталонной моделью нейросетевого регулятора можно сделать следующие выводы:

1. Синтезированная система с эталонной моделью нейросетевого регулятора относится к классу адаптивных систем управления, в которых контуры адаптации функционируют по замкнутому циклу с непрерывной коррекцией параметров системы в ответ на изменения внешних и внутренних условий. При этом с ростом числа контуров настройки (адаптации) в системе повышается порядок, влияющий на динамику замкнутой системы, ее устойчивость и робастность.
2. Нейросетевой регулятор эталонной моделью является более предпочтительным при управлении нелинейными объектами, так как используемые им нейросети, нелинейные по своей природе, наилучшим образом позволяют решать задачи с нелинейностями.
3. Показано при обучении нейросетевых моделей объекта управления и регулятора, что значения среднеквадратических ошибок характеристик производительности обучения (см. рис. 13 и 17) настолько малы, что обеспечивают наилучшее решение задачи слежения за траекторией эталонной модели (с минимизацией евклидовой нормы).
4. Практическая значимость адаптивного управления по эталонной модели с применением нейросетевых регуляторов состоит в расширении возможностей для применения к различным классам управляемых процессов [2].

5. Результаты моделирования нейросетевой архитектуры регулятора и объекта управления на примере ДПТ показывают, что адаптивное управление по эталонной модели позволяет в точности отслеживать сигнал задатчика и указывает на робастную устойчивость управления, т. е. гарантировать нечувствительность характеристик поведения регулятора при вариациях параметров модели объекта идентификации в диапазоне, определяемом выбранными параметрами тестовых сигналов в процессе обучения нейросетей объекта и регулятора.

СПИСОК ЛИТЕРАТУРЫ

1. Барышников С. О. Модели и алгоритмы управления объектами водного транспорта в условиях цифровой трансформации : монография / С. О. Барышников, Д. В. Дмитриенко, В. В. Сахаров, А. А. Чертков. — Санкт-Петербург: ООО «Заневская площадь», 2022. — 520 с.
2. Сахаров В. В. Модели и алгоритмы оптимизации технологических процессов на объектах водного транспорта в среде MatLab / В. В. Сахаров, А. А. Кузьмин, А. А. Чертков. — Санкт-Петербург: ФГБОУ ВО «Государственный университет морского и речного флота имени адмирала С. О. Макарова», 2015. — 436 с. — EDN ULLID.
3. Чертков А. А. Алгоритм идентификации параметров моделей производственных функций при помощи нейронной сети / А. А. Чертков, С. В. Сабуров, Я. Н. Каск // Вестник государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2023. — Т. 15. — № 6. — С. 1096–1104. DOI: 10.21821/2309-5180-2023-15-6-1096-1104. — EDN AQZOGP.
4. Цвенгер И. Г. Применение нейросетевых регуляторов в системах управления электроприводами / И. Г. Цвенгер, И. Р. Низамов // Вестник Технологического университета. — 2017. — Т. 20. — № 8. — С. 111–114. — EDN VZSIHV.
5. Чертков А. А. Параметрическая настройка ПИД-регуляторов динамических систем средствами MATLAB / А. А. Чертков, Д. С. Тормашев, С. В. Сабуров // Вестник государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2014. — № 5(27). — С. 164–171. — EDN SWLTUJ.
6. Хайкин С. Нейронные сети: полный курс. — 2-е изд.; пер. с англ. / С. Хайкин. — М.: Издательский дом «Вильямс», 2016. — 1104 с.
7. Вакуленко С. А. Практический курс по нейронным сетям / С. А. Вакуленко, А. А. Жихарева. — СПб., Ун-т ИТМО, 2018. — 71 с.
8. Бобцов А. А. Исполнительные устройства и системы для микроперемещений / А. А. Бобцов, В. И. Бойков, С. В. Быстров, В. В. Григорьев, П. В. Карев [и др.]. — СПб.: Университет ИТМО, 2017. — 134 с.
9. Давидон Б. Автоматическая оптимизация Simulink моделей и регуляторов // Портал научно-практических публикаций [Электронный ресурс]. — Режим доступа: <https://portalnp.snauka.ru/2013/10/1194> (дата обращения: 01.03.2025)
10. Белов М. П. Синтез нейросетевого регулятора для двухмассовой электромеханической системы привода подачи токарного станка / М. П. Белов, И. С. Носиров, А. М. Белов // Известия СПбГЭТУ ЛЭТИ. — 2018. — № 8. — С. 70–76. — EDN YNMJVR.
11. Емельянов А. А. Математическое моделирование двигателя постоянного тока в системе относительных единиц в Matlab и Си / А. А. Емельянов, В. В. Бесклеткин, И. М. Агзамов [и др.] // Молодой ученый. — 2019. — № 11(249). — С. 1–7. — EDN ZAHEJV.
12. Wang L. PID Control System Design and Automatic Tuning using MATLAB/Simulink / L. Wang — John Wiley & Sons, Ltd, 2020. — 344 p. DOI: 10.1002/9781119469414.index.

REFERENCES

1. Baryshnikov, S. O., D. V. Dmitrienko, V. V. Sakharov and A. A. Chertkov. *Modeli i algoritmy upravleniya ob'ektami vodnogo transporta v usloviyakh tsifrovoy transformatsii* SPb: Izd. «Zanevskaya ploschad'», 2022: 520.
2. Sakharov, V. V., A. A. Kuz'min and A. A. Chertkov. *Modeli i algoritmy optimizatsii tekhnologicheskikh protsessov na ob'ekтах vodnogo transporta v srede MatLab* Sankt-Peterburg: Federal'noe gosudarstvennoe byudzhethoe obrazovatel'noe uchrezhdenie vysshego obrazovaniya Gosudarstvennyy universitet morskogo i rechnogo flota im. admirala S. O. Makarova, 2015: 436.

3. Chertkov, A. A., C. V. Saburov and Ya. N. Kask. "Algorithm for identifying parameters of production function models using a neural network." *Vestnik gosudarstvennogo universiteta morskogo i rechnogo flota im. admirala S. O. Makarova* 15.6 (2023): 1096–1104. DOI: 10.21821/2309-5180-2023-15-6-1096-1104.
4. Tsvenger, I. G. and I. R. Nizamov. "Primenenie neyrosetevykh regulyatorov v sistemakh upravleniya elektropivodami." *Vestnik Tekhnologicheskogo universiteta* 20.8 (2017): 111–114.
5. Chertkov, A. A., D. S. Tormashev and S. V. Saburov. "Dynamic systems parametric arrange by means pid tuner in matlab." *Vestnik gosudarstvennogo universiteta morskogo i rechnogo flota im. admirala S. O. Makarova* 5(27) (2014): 164–171.
6. Khaikin, Simon. *Neural Networks: A Complete Course*. 2nd Edition. with anrl. Moscow: Williams Publishing House, 2006: 1104.
7. Vakulenko, S. A. and A. A. Zhikhareva. *Prakticheskiy kurs po neyronnym setyam*. SPb.: Universitet ITMO, 2018: 71.
8. Bobtsov A. A., V. V. Grigoriev, and P. V. Karev et al. *Actuating devices and systems for micro-movements*. St. Petersburg: ITMO University, 2017: 134.
9. Davidov B. Automatic optimization of Simulink models and controllers Portal of scientific and practical publications Web. 1 Mar. 2025 <<https://portalnp.snauka.ru/2013/10/1194>>
10. Belov, M. P., I. S. Nosirov and A. M. Belov. "Synthesis neural network controller for two-mass electromechanical system of lathe machine's feed drive." *Izvestiya SPbGETU LETI* 8 (2018): 70–76.
11. Emel'yanov, A. A., V. V. Beskletkin and I. M. Agzamov et al. "Matematicheskoe modelirovanie dvigatelya postoyannogo toka v sisteme otnositel'nykh edinit v Matlab i Si." *Molodoy uchenyy* 11(249) (2019): 1–7.
12. Wang, L. *PID Control System Design and Automatic Tuning using MATLAB/Simulink* John Wiley & Sons, Ltd, 2020: 344. DOI: 10.1002/9781119469414.index.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Сахаров Владимир Васильевич —
 доктор технических наук, профессор
 ФГБОУ ВО «ГУМРФ имени адмирала
 С. О. Макарова»
 198035, Российская Федерация, Санкт-Петербург,
 ул. Двинская, 5/7
 e-mail: _saharov_@rambler.ru

Чертков Александр Александрович —
 доктор технических наук, доцент
 ФГБОУ ВО «ГУМРФ имени адмирала
 С. О. Макарова»
 198035, Российская Федерация, Санкт-Петербург,
 ул. Двинская 5/7
 e-mail: chertkov51@mail.ru,
kaf_electricautomatic@gumrf.ru

Каск Ярослав Николаевич —
 кандидат технических наук, доцент
 ФГБОУ ВО «ГУМРФ имени адмирала
 С. О. Макарова»
 198035, Российская Федерация, Санкт-Петербург,
 ул. Двинская, 5/7
 e-mail: rgam2010@yandex.ru,
kaf_electricautomatic@gumrf.ru

INFORMATION ABOUT THE AUTHORS

Saharov Vladimir V. —
 Grand PhD in Technical Sciences, professor,
 Admiral Makarov State University of Maritime
 and Inland Shipping
 5/7 Dvinskaya Str., St. Petersburg, 198035,
 Russian Federation
 e-mail: _saharov_@rambler.ru

Chertkov, Alexandr A. —
 Grand PhD in Sciences, associate professor
 Admiral Makarov State University of Maritime
 and Inland Shipping
 5/7 Dvinskaya Str., St. Petersburg, 198035,
 Russian Federation
 e-mail: chertkov51@mail.ru,
kaf_electricautomatic@gumrf.ru

Kask, Yaroslav N. —
 PhD
 Admiral Makarov State University of Maritime
 and Inland Shipping
 5/7 Dvinskaya Str., St. Petersburg, 198035,
 Russian Federation
 e-mail: rgam2010@yandex.ru,
kaf_electricautomatic@gumrf.ru

Статья поступила в редакцию 12 июня 2025 г.
 Received: June 12, 2025.