

Научная статья

УДК 621.313.2+004.032.26

doi: 10.17223/19988605/74/4

Модификация синтеза нейросетевого регулятора двигателя постоянного тока**Игорь Альбертович Шмидт¹, Илья Алексеевич Попов², Дмитрий Романович Жуков³***^{1, 2, 3} Пермский национальный исследовательский политехнический университет, Пермь, Россия**¹ shmidt@pstu.ru**² ilya.popov2801@mail.ru**³ dimonzhukov1503@gmail.com*

Аннотация. Предложен и исследован подход к синтезу нейросетевого регулятора с использованием модификации функции потерь. В качестве объекта управления рассмотрен двигатель постоянного тока, его модель дополнена зависимостью сопротивления обмотки якоря от температурного коэффициента. Предложена также модификация архитектуры путем использования слоев Batch-Normalization в скрытых слоях, метода оптимизации Nadam и пакетного градиентного спуска. Сформированы и обоснованы основные правила задания критериев в выходных нейронах искусственной нейронной сети. Предложен новый способ задания управляющего воздействия для исключения появления ложного влияния не используемых выходов на процесс обучения искусственной нейронной сети. Моделирование на модифицированной модели двигателя постоянного тока продемонстрировало высокое качество управления: точное поддержание заданной скорости, соблюдение ограничений по току и отсутствие колебаний тока якоря при исследованных режимах.

Ключевые слова: искусственная нейронная сеть; нейрорегулятор; обучение нейронной сети; функция потерь; двигатель постоянного тока; критерий управления.

Для цитирования: Шмидт И.А., Попов И.А., Жуков Д.Р. Модификация синтеза нейросетевого регулятора двигателя постоянного тока // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. 2026. № 74. С. 40–50. doi: 10.17223/19988605/74/4

Original article

doi: 10.17223/19988605/74/4

Neural network controller synthesis modification for a direct current motor**Igor A. Shmidt¹, Ilya A. Popov², Dmitriy R. Zhukov³***^{1, 2, 3} Perm National Research Polytechnic University, Perm, Russian Federation**¹ shmidt@pstu.ru**² ilya.popov2801@mail.ru**³ dimonzhukov1503@gmail.com*

Abstract. This paper proposes and investigates a modified approach to synthesizing a neural-network controller based on the loss-function substitution method. A DC motor is considered as the control object. The model is extended to include a temperature-dependent armature winding resistance. The architecture is improved by using Batch Normalization layers in the hidden layers and the Nadam optimizer together with batch gradient descent. Principles for assigning performance criteria to the network's output neurons are formulated and justified. A novel method for determining control actions is proposed to eliminate the spurious influence of inactive outputs on the training process. Simulation of the upgraded DC-motor model demonstrates high control performance: accurate maintenance of the target speed, adherence to current limits, and absence of armature current oscillations under the examined operating modes.

Keywords: artificial neural network; neuroregulator; neural network training; loss function; DC motor; control criterion.

For citation: Shmidt, I.A., Popov, I.A., Zhukov, D.R. (2026) Neural network controller synthesis modification for a direct current motor. *Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel'naja tehnika i informatika – Tomsk State University Journal of Control and Computer Science*. 74. pp. 40–50. doi: 10.17223/19988605/74/4

Введение

Искусственные нейронные сети (ИНС) и методы их обучения активно развиваются и применяются в современных технологических системах для повышения эффективности управления. Их использование особенно актуально в случаях, когда классические методы регулирования не обеспечивают необходимого уровня качества. В зависимости от специфики объекта управления (ОУ) и задач управления существует множество различных методов синтеза регуляторов на основе ИНС, базирующихся на различных методах и правилах глубокого машинного обучения.

На данный момент существует ряд обзоров, рассматривающих существующие методы глубокого обучения в управлении сложными объектами, представляющими собой физические, механические и химические системы [1, 2]. Использование ИНС применительно к производственным процессам рассматривается в работах [3, 4] и для непосредственного управления процессами, и для создания моделей объектов управления. Кроме того, существует множество исследований, посвященных синтезу регуляторов для различных типов приводов, охватывающих как системы автоматического управления (САУ) [5, 6], включая тестирование алгоритмов на реальных объектах [7–9], так и анализ существующих подходов в рамках обзорных работ [10].

Методология обучения и применения ИНС в САУ варьирует от «подражания» ПИД-регулятору или подбора его коэффициентов с помощью ИНС [6, 11] до инверсного управления с обучением «без учителя» на модели ОУ [12]. Во всех рассмотренных работах применяется стандартный подход к вычислению функции потерь ИНС, основанный на сравнении выходных значений нейронов последнего слоя с заданным целевым значением.

Ранее в работе [12] был предложен оригинальный подход к синтезу регулятора на основе ИНС, т.е. нейрорегулятора, предполагающий обучение ИНС на модели объекта управления с подменой метода вычисления функции потерь. Этот подход заключается в замене традиционного расчета ошибки на расчет специализированных критериев, отражающих целевые показатели качества управления (время нарастания функции, перерегулирование, статическая ошибка, соблюдение ограничений, нелинейностей и особенностей ОУ), которые будут вносить величины ошибки в функцию потерь по выходным нейронам ИНС и, таким образом, влиять на процесс ее обучения.

Однако необходимо учитывать, что внесение множества одновременно учитываемых критериев эффективности в случае, когда достижение одного критерия приводит к ухудшению другого, может свести задачу обучения нейронной сети к сложной многокритериальной задаче, обладающей труднодостижимыми Парето-оптимумами. В разделе 2.4. работы [13] такой случай описан на примере применения эволюционных алгоритмов в многокритериальных задачах, а именно задачи одновременной минимизации времени нарастания и перерегулирования переходной характеристики САУ.

В настоящей работе предлагается развитие подхода из работы [12], поскольку последующие исследования показали, что предложенный в ней нейрорегулятор имеет ряд недостатков и требует доработки для его практического применения.

1. Постановка задачи

Для устранения описанных выше недостатков в настоящей работе были поставлены следующие задачи: определение конфигурации и подходов к обучению ИНС, обеспечивающих устойчивый синтез нейрорегулятора для модели двигателя постоянного тока (ДПТ); интеграция дополнительного возмущающего воздействия на ОУ; отслеживание колебательных процессов тока якоря для оценки различных конфигураций ИНС при синтезе нейрорегулятора; выбор оптимальной реализации с соблюдением следующих требований к управлению:

- 1) минимизация отклонения угловой скорости вращения вала от заданного значения;
- 2) снижение колебательности тока якоря;
- 3) ограничение длительного превышения тока якоря выше трех номинальных значений.

Процесс обучения и тестирования нейрорегулятора осуществлялся на модифицированной модели ДПТ, используемой в работе [12]. Математическая модель ДПТ независимого возбуждения,

работающего при постоянном магнитном потоке, представлена системой дифференциальных уравнений электрической цепи и вращающейся части двигателя

$$\begin{cases} u_{\text{я}} = R_{\text{я}}(1 + k_t)i_{\text{я}} + L_{\text{я}} \frac{di_{\text{я}}}{dt} + e, \\ M - M_c = J \frac{d\omega}{dt}, \end{cases} \quad (1)$$

где $u_{\text{я}}$ – напряжение на якорной обмотке двигателя, $R_{\text{я}}$ – активное сопротивление якорной цепи, k_t – температурный коэффициент, $i_{\text{я}}$ – ток якоря, $L_{\text{я}}$ – индуктивность якорной цепи, e – электродвижущая сила (ЭДС) якоря, M – электромагнитный момент двигателя, M_c – момент сопротивления движению, J – суммарный момент инерции якоря и нагрузки, ω – скорость вращения вала двигателя. Момент сопротивления движению M_c является возмущающим воздействием, которое подается на вход ОУ.

Для проверки возможности нейрорегулятора учитывать множество возмущающих воздействий в уравнение якорной цепи в системе ДУ (1) был добавлен коэффициент k_t , учитывающий изменение сопротивления якоря в зависимости от температуры:

$$k_t = \alpha(T_2 - T_1) + \Delta k_t, \quad (2)$$

где α – температурный коэффициент сопротивления, T_1 – начальная температура якорной цепи, T_2 – температура якорной цепи после нагрева. Коэффициент k_t также подается на вход ОУ. В (2) коэффициент k_t зависит от неконтролируемого возмущения Δk_t .

В демонстрационных целях для увеличения значимости возмущающего воздействия k_t задается таким образом, что диапазон изменения сопротивления значительно превышает диапазон, характерный для реальных двигателей.

Дифференциальные уравнения (1) дополняются алгебраическими уравнениями (3), описывающими зависимости для электродвижущей силы и вращающего момента двигателя:

$$\begin{cases} e = k_e \Phi \omega = C_e \omega, \\ M = k_m \Phi i_{\text{я}} = C_m i_{\text{я}}, \end{cases} \quad (3)$$

где Φ – поток, создаваемый обмоткой возбуждения, k_e – коэффициент связи между скоростью и ЭДС, k_m – коэффициент связи между током якоря и электромагнитным моментом, C_e , C_m – переменные, описывающие связь между скоростью вращения и ЭДС и между током якоря и электромагнитным моментом.

2. Оптимизация процесса обучения и архитектуры ИНС

В подходе из работы [12] при обучении ИНС используется обучающая выборка $V = \{P_i, P'_i\}$, содержащая векторы текущего состояния ОУ P_i , подаваемые на вход ИНС, и векторы критериев управления P'_i , необходимые для расчета функции потерь при помощи критериев управления, которые будут рассмотрены в разд. 3. Каждая эпоха обучения состоит из n тактов управления, на каждом из которых вырабатывается управляющее воздействие на модель ОУ, после чего формируются векторы P_i и P'_i .

Для решения задачи поддержания заданной скорости в векторе P_i необходимо учитывать следующие параметры ДПТ на i -м такте процесса управления: задание угловой скорости $\omega_{\text{зад},i}$; угловую скорость ω_i ; ток якоря $i_{\text{я},i}$; нагрузку, выраженную статическим моментом сопротивления на валу $M_{c,i}$; температурный коэффициент $k_{t,i}$, отражающий изменение характеристик двигателя при нагреве. Кроме того, чтобы нейронный регулятор корректно воспринимал динамику системы, в его входной вектор включаются значения угловой скорости и тока якоря предыдущих двух тактов работы ДПТ. Таким образом, входной вектор состоит из 9 значений: $P_i = [\omega_{\text{зад},i}; \omega_i; i_{\text{я},i}; M_{c,i}; k_{t,i}; \omega_{i-1}; \omega_{i-2}; i_{\text{я},i-1}; i_{\text{я},i-2}]$. Выход ИНС отражает напряжение, подаваемое на якорную обмотку двигателя, т.е. ИНС вырабатывает управляющее воздействие u_i для ОУ.

Часть обучающей выборки формировалась вручную и содержит 3 изменяющихся во времени параметра: $\omega_{\text{зад}}$; M_c ; k_t , нормализованных относительно номинальных значений. Прочие данные о состоянии ОУ определяются в процессе управления моделью при обучении ИНС. Обучающая выборка была

сформирована таким образом, чтобы равнозначно отразить все желаемые режимы работы ДПТ и все возможные при этом переходы из одного режима в другой минимально повторяющееся количество раз. Для проверки результатов обучения по аналогичным правилам была сформирована тестовая выборка, отражающая другие вариации этих режимов и переходов между ними.

Поскольку входные параметры нормализуются и могут принимать отрицательные значения, в качестве функции активации для скрытых слоев используется гиперболический тангенс (\tanh). Для выходного слоя применяется линейная функция активации, что является стандартным подходом для задач регрессии.

Подбор гиперпараметров осуществлялся экспериментальным путем, так как такой подход является довольно распространенным при отсутствии возможности использования уже известной архитектуры или готовой модели для достижения конкретной цели [14]. Итоговая конфигурация приведена в разд. 4.

2.1. Внедрение слоев *Batch-Normalization*

Помимо номинальных режимов работы, ДПТ может работать в условиях повышенной нагрузки, при которых нормированные относительно номинальных значений параметры, включая ток якоря и механический момент, принимают значения больше единицы. При использовании в скрытых слоях активационной функции \tanh (гиперболический тангенс), выходные значения которой лежат в диапазоне от -1 до $+1$, часть активаций попадает в область насыщения. Это приводит к затуханию градиентов и, следовательно, к замедлению или полному прекращению процесса обучения.

Данная проблема была решена при помощи добавления слоев *Batch-Normalization* (BN) [15]. Суть метода заключается в преобразовании входных данных слоя для приведения их к нулевому среднему значению и единичному стандартному отклонению. Такой подход снижает зависимость сети от масштаба исходных данных и повышает устойчивость обучения нейронной модели.

В работе [16] описывается, что BN-слои сглаживают ландшафт оптимизации, это, в свою очередь, делает градиенты более предсказуемыми, что ускоряет сходимость и помогает избежать локальных минимумов при поиске глобального.

Для функций активации типа \tanh , в которых присутствует ограничение, наиболее эффективным способом является применение BN после функции активации, поскольку оно дает более устойчивое и симметричное распределение, уменьшает насыщение и облегчает обучение [17].

2.2. Повышение стабильности обучения ИНС

Обучение нейрорегулятора базируется на классическом алгоритме обратного распространения ошибки с использованием градиентного спуска. Тем не менее уже на первоначальных экспериментах стало ясно, что выбор алгоритма оптимизации напрямую влияет на устойчивость и скорость сходимости модели, в том числе на появление явления «взрывных» градиентов, которое описанное в работе [18]. Данное явление проявляется в виде экстремального роста значений градиентов при обратном распространении ошибки, что приводит к нестабильности процесса обучения: значение ошибки не уменьшается с прохождением эпох, а изменяется от крайне больших до крайне малых значений. При этом наилучшая полученная в процессе обучения конфигурация, как правило, находилась в зоне появления «взрывных градиентов», т.е. она обнаруживалась случайным образом в результате «взрывного» смещения весов. При подобном процессе обучения невозможно гарантировать нахождение оптимальной конфигурации регулятора. График обучения представлен на рис. 1, а.

Одной из причин возникновения «взрывных» градиентов является специфика обновления весов при использовании стохастического градиентного спуска (СГС) и мини-пакетного градиентного спуска (МПС). Поскольку обучающая выборка содержит режимы, существенно различающиеся между собой, их применение приводит к тому, что обновление весов осуществляется на основе ограниченной подвыборки, не отражающей всей совокупности режимов, из-за чего величины смещений весов изменяются нестабильно.




Рис. 1. Графики процессов обучения ИНС: *a* – метод Нестерова с МПГС; *b* – метод Nadam с ПГС и слоями BN
 Fig. 1 The ANN training processes plots: *a*) Nesterov with Mini-batch SGD; *b*) Nadam with SGD and BN layers

Для обеспечения стабильности процесса обучения в данной работе применялся пакетный градиентный спуск (ПГС), при котором обновление весов выполнялось после обработки всей обучающей выборки. Вместо классического алгоритма Нестерова, используемого в работе [12], в качестве алгоритма оптимизации в данной работе предлагается использовать ускоренный по Нестерову метод адаптивной оценки моментов Nadam, впервые описанный в [19] и доказавший свою эффективность при обучении моделей на временных рядах [20]. Такой подход позволил повысить устойчивость обучения и сгладить колебания градиентов. График обучения с устраненной проблемой взрывных градиентов представлен на рис. 1, *b* и обозначен как e_1 . Подробное описание графика e_2 на рис. 1, *b* представлено в разд. 3.1.

3. Принцип учета критериев управления в функции потерь ИНС

В данной работе используется два основных критерия управления для синтеза нейрорегулятора угловой скорости двигателя, разработанных в работе [12]: минимизация отклонения угловой скорости вращения от заданной; ограничение превышения тока якоря над заданным значением. Каждый критерий выражен значением ошибки, рассчитываемой на каждом такте управления.

Рассмотрим расчет критериев на i -м такте управления (среднеквадратичной ошибки): минимума отклонения угловой скорости вращения

$$e_{\omega,i} = (\omega_i - \omega_{3,i})^2, \quad (4)$$

где ω_i – реальная угловая скорость на i -м шаге, $\omega_{3,i}$ – задание по угловой скорости на i -м шаге, и минимизации превышения тока над заданным значением

$$e_{c,i} = \left(f(i_{я,i}) (|i_{я,i}| - i_{огр}) \right)^2, \quad f(i_{я,i}) = \begin{cases} 0 & \text{при } |i_{я,i}| < i_{огр}, \\ 1 & \text{при } |i_{я,i}| \geq i_{огр}, \end{cases} \quad (5)$$

где $i_{я,i}$ – реальное значение тока якоря на i -м шаге, $i_{огр}$ – заданное значение ограничения тока якоря.

Общая ошибка (функция потерь) по выходным нейронам ИНС за эпоху обучения рассчитывается следующим образом:

$$C = \frac{1}{p} \sum_{j=1}^m \left(\frac{1}{n} \sum_{i=1}^n k_{j,i} e_{j,i} \right) = \frac{1}{p} \left(\frac{1}{n} \sum_{i=1}^n k_{\omega,i} e_{\omega,i} + \frac{1}{n} \sum_{i=1}^n k_{c,i} e_{c,i} \right), \quad (6)$$

где p – количество выходных нейронов, m – количество введенных критериев, n – количество тактов управления, $e_{j,i}$ – значение ошибки по j -му критерию управления на i -м такте управления, $k_{j,i}$ – коэффициент значимости j -го критерия на i -м такте управления, $k_{\omega,i}$ – коэффициент значимости критерия минимума отклонения угловой скорости вращения на i -м такте управления, $k_{c,i}$ – коэффициент значимости критерия минимизации превышения тока над заданным значением на i -м такте управления.

Немаловажным аспектом является подбор коэффициентов $k_{j,i}$, поскольку они влияют на значимость j -го критерия на i -ом такте управления при обучении нейрорегулятора. Коэффициент значимости $k_{j,i}$ позволяет варьировать добавляемую величину $e_{j,i}$ на каждом такте в общую ошибку C , тем самым задавая относительный вклад данного критерия и его значимость в процессе обучения.

3.1. Исключение влияния неиспользующихся нейронов при внедрении критериев управления

Ранее в работе [12] был предложен подход, когда под каждый критерий управления в выходном слое ИНС выделялся свой нейрон, при этом в качестве управляющего воздействия u_i использовалось выходное значение только первого нейрона, в котором происходит расчет критерия $e_{\omega,i}$.

Каждый критерий управления фактически является слагаемым в расчете суммарной общей ошибки по выходным нейронам (6), в каком бы выходном нейроне он ни рассчитывался. Однако было обнаружено, что, несмотря на это, имеет существенное значение, рассчитываются ли критерии в нейронах, выходные значения которых используются при управлении. Связано это с тем, что все значения a с выходных нейронов, используются в формуле расчета смещения по каждому весу при обратном распространении ошибки [21]:

$$\frac{\partial C}{\partial w_{jk}^l} = a_k^{l-1} \sigma'(z_j^l) \frac{\partial C}{\partial a_j^l}, \quad (7)$$

где C – значение функции потерь (общая ошибка за всю эпоху обучения), w – значение веса, a – выходное значение нейрона (значение активации), σ – функция активации, z – взвешенная сумма всех входов, l – индекс слоя, j – индекс нейрона в слое l , k – индекс нейрона в слое $l-1$.

То есть выделение выходного нейрона под каждый дополнительный критерий, сигнал с которого не используется в процессе управления, а лишь служит для расчета слагаемого общей ошибки, приводит к лишнему влиянию этих нейронов на веса ИНС при обратном распространении ошибки. Следовательно, в процессе обучения при управлении не задействуются соответствующие значения выходных нейронов, из-за чего изменение весов не приводит к уменьшению ошибки по данным критериям: ошибки по связанным с манипулируемой величиной критериям уменьшаются, тогда как по несвязанным – увеличиваются. При наличии нейронов, выходные значения которых не используются, регулятору не удастся определить влияние соответствующих весов на функцию потерь из-за отсутствия обратной связи между ошибкой по критериям и сигналом с выходного нейрона.

В данной работе предлагается использовать отдельный нейрон под каждый критерий, при этом в качестве значения манипулируемой величины использовать сумму значений выходных нейронов, как показано на рис. 3 в разд. 4.

На рис. 1, *b* показаны процессы изменения функции потерь при обучении нейрорегулятора с использованием в качестве u_i выходного значения только первого нейрона (e_2) и суммы значений выходных нейронов (e_1). Из рисунка видно, что в момент, когда управляющее воздействие, вырабатываемое нейрорегулятором, приводит к превышению током якоря допустимого значения, происходит рост ошибки по ограничивающему критерию. Ошибка регулятора при старом подходе продолжает расти, в то время как регулятор при новом подходе учитывает критерий (5) и продолжает корректное обучение.

Отсюда следует, что для корректного учета критериев управления, во-первых, нельзя допускать использования выходных нейронов, значения которых не связаны с некоторой манипулируемой величиной, во-вторых, в нейронах, влияющих на эту величину, необходимо учитывать все критерии, напрямую или косвенно зависящие от этой величины.

Таким образом, использование модифицированного подхода позволяет получить нейрорегулятор, корректно учитывающий все критерии управления.

3.2. Необходимость учета качества тока якоря при обучении ИНС

Помимо основных введенных критериев управления (5) и (6), существенное значение имел бы критерий, учитывающий поведение тока во времени, а именно минимизирующий колебательность

тока, так как это является важным условием качественного управления, однако формализация данного критерия представляет значительные трудности. В отличие критерия (6), который можно явно задать через пороговое условие, отсутствие колебаний тока не имеет однозначной количественной метрики. На практике оценка «качества» формы тока часто носит экспертный или визуальный характер: по графику можно легко определить удачную конфигурацию регулятора, при которой ток не содержит существенных колебаний. Однако по функции потерь этого сделать не получится: в процессе обучения ИНС может продолжать снижать ошибку по целевому критерию (5), однако ток якоря становится все более нестабильным – возрастают амплитуда и частота колебаний, т.е. текущая функция потерь не отражает реальных требований к качеству управления.

На текущий момент оценка «качества» формы тока производится визуальным путем по итогам регулирования. В результате экспертной оценки было обнаружено, что оптимизация процесса обучения позволила получить конфигурации, в которых отсутствуют колебания тока.

Таким образом, отсутствие формализованного критерия для подавления колебаний тока остается одним из узких мест разработки нейросетевого регулятора. Несмотря на то, что визуальная оценка позволяет выделить удачные конфигурации на отдельных эпохах обучения, автоматизация этого процесса необходима и требует дальнейших исследований и разработки гибких математических показателей, описывающих стабильность тока.

4. Итоговая архитектура ИНС

Конфигурация нейронной сети представляет собой полносвязный перцептрон, включающий входной слой из 9 параметров, три скрытых слоя и выходной слой с функцией активации Identity (linear) и одним нейроном. Первый и второй скрытые слои содержат по три нейрона с функцией активации tanh, за каждым из них следует слой BN. Третий скрытый слой состоит из одного нейрона с функцией активации tanh. Полученный экспериментальным путем вариант архитектуры (рис. 2, b) показывает наилучшую эффективность.

Инициализация весов осуществляется методом Xavier. Механизм оптимизации основан на алгоритме ПГС с обратным распространением ошибки. В качестве метода обновления весов применяется Nadam при скорости обучения 0,002. Для введенных критериев (5) и (6) оптимальными оказались коэффициенты $k_{j,i}$, равные единице, т.е. они должны равнозначно учитываться в процессе обучения. На рис. 2 представлены итоговая архитектура из работы [12] и полученная в данной работе после модификации.




Рис. 2. Сравнение архитектур ИНС: *a* – предыдущая, *b* – текущая
 Fig. 2 Comparison of ANN architectures: *a* – previous, *b* – current

Применение описанных модификаций архитектуры повысило устойчивость и предсказуемость процесса обучения: устранились резкие колебания функции потерь и обеспечилась более плавная сходимость (см. рис. 1, b). При этом требуемое число эпох для достижения устойчивого решения увеличилось

примерно в 3,5 раза. Такое увеличение времени обучения можно считать приемлемым с учетом вышеописанных преимуществ.

Предложенный подход к синтезу нейросетевого регулятора применим не только для двигателя постоянного тока. В качестве ОУ может быть рассмотрена, в принципе, любая динамическая система, единственным ограничением является наличие ее адекватной математической модели.

Синтезированный нейрорегулятор тестировался на выборке, отличной от обучающей, в ходе чего были построены графики изменения параметров системы регулирования во времени, представленные на рис. 3. Первая часть графика демонстрирует регулирование угловой скорости ДПТ ω (1) в зависимости от задания угловой скорости $\omega_{\text{зад}}$. На второй части представлены входные воздействия на ДПТ: момент сопротивления M_c (1) и температурный коэффициент k_t (2). На третьей части представлен ток якоря i_a (1), величина которого ограничена тремя номинальными значениями критерием для регулятора.




Рис. 3. Графики изменения во времени: угловой скорости (оранжевый) и ее задания (синий); момента сопротивления (зеленый) и температурного коэффициента (красный); тока якоря (фиолетовый) при моделировании системы регулирования с обученным нейрорегулятором

Fig. 3 Simulation of a control system with a trained neural controller: angular velocity (orange) and its setpoint (blue); resistance torque (green) and temperature coefficient (red); armature current (violet)

Результаты моделирования, представленные на рис. 3, подтверждают устойчивость работы разработанного регулятора: изменение нагрузки компенсируется заранее практически без снижения скорости, а при смене уставки наблюдается лишь минимальное перерегулирование, не превышающее 1%. На всех исследованных режимах токовые колебания отсутствуют (оценка колебаний производилась экспертно): возникающие переходные процессы быстро затухают, обеспечивая стабильность и надежность функционирования системы.

Заключение

Предложен усовершенствованный метод синтеза нейросетевого регулятора для ДПТ на основе модификации функции потерь, который заключается в замене традиционного расчета ошибки на расчет специализированных критериев, отражающих целевые показатели качества управления. В работе показано, что применение BN, ПГС и Nadam существенно повышает стабильность процесса обучения.

Моделирование подтвердило высокое качество управления даже при значительных входных воздействиях на ОУ: точность поддержания заданной скорости, быстрое затухание переходных процессов и минимальное перерегулирование.

Сформированы основные правила учета критериев на выходных нейронах ИНС.

Предложенный способ задания управляющего воздействия устраняет ложное влияние «неуправляемых» выходных нейронов на градиенты и позволяет корректно находить локальные минимумы функции потерь.

Список источников

1. Mohammadzaheri M., Chen L., Grainger S. A Critical Review of the Most Popular Types of Neuro Control // *Asian Journal of Control*. 2012. V. 14 (1). P. 1–11. doi: 10.1002/asjc.449
2. Чернодуб А.Н., Дзюба Д.А. Обзор методов нейроуправления // *Проблемы программирования*. 2011. № 2. С. 79–94.
3. Bonassi F., Farina M., Xie J., Scattolini R. On Recurrent Neural Networks for learning-based control: recent results and ideas for future developments // *Journal of Process Control*. 2022. V. 114. P. 92–104. doi: 10.1016/j.jprocont.2022.04.01
4. Chinnam R.B., Kolarik W.J. Neural network-based quality controllers for manufacturing systems // *International Journal of Production Research*. 1997. V. 35 (9). P. 2601–2620. doi: 10.1080/002075497194688
5. Nouri K., Dhaouadi R., Braiek N.B. Nonlinear speed control of a dc motor drive system with online trained recurrent neural network // 9th IEEE International Workshop on Advanced Motion Control, 2006. Istanbul, Turkey. P. 704–708. doi: 10.1109/amc.2006.1631746
6. Вельченко А.А., Павлюковец С.А., Радкевич А.А., Ибрагим А.К. Энергоэффективное нейросетевое управление бесколлекторным двигателем постоянного тока // *Энергетика. Известия высших учебных заведений и энергетических объединений СНГ*. 2025. Т. 68, № 1. С. 45–57. doi: 10.21122/1029-7448-2025-68-1-45-57
7. Nouri K., Dhaouadi R., Braiek N.B. Adaptive Control of a Nonlinear DC Motor Drive Using Recurrent Neural Networks // *Applied Soft Computing*. 2008. V. 8. P. 371–382.
8. Rubaai A., Young P. Hardware/Software Implementation of Fuzzy-Neural-Network Self-Learning Control Methods for Brushless DC Motor Drives // *IEEE Transactions on Industry Applications*. 2016. V. 52 (1). P. 414–424. doi: 10.1109/tia.2015.2468191
9. Nouri K., Dhaouadi R., Braiek N.B. Adaptive control of a nonlinear dc motor drive using recurrent neural networks // *Applied Soft Computing*. 2008. V. 8, is. 1. P. 371–382. doi: 10.1016/j.asoc.2007.03.002
10. Kaminski M., Tarczewski T. Neural Network Applications in Electrical Drives – Trends in Control, Estimation, Diagnostics, and Construction // *Energies*. 2023. V. 16 (11). Art. 4441. doi: 10.3390/en16114441
11. Lee Y.-S., Jang D.-W. Optimization of Neural Network-Based Self-Tuning PID Controllers for Second Order Mechanical Systems // *Applied Sciences*. 2021. V. 11 (17). Art. 8002. doi: 10.3390/app11178002
12. Шмидт И.А., Даденков Д.А. Использование искусственной нейронной сети в электромеханической системе регулирования скорости двигателя постоянного тока // *Электротехника*. 2024. № 11. С. 26–32.
13. Fleming P.J., Purshouse R.C. Evolutionary algorithms in control systems engineering: a survey // *Control Engineering Practice*. 2002. V. 10 (11). P. 1223–1241. doi: 10.1016/s0967-0661(02)00081-3
14. Обходский А.В., Кульбакин Д.Е., Обходская Е.В., Попов А.С., Родионов Е.О., Сачков В.И., Чернов В.И., Чойнзонов Е.Л. Программный комплекс нейросетевой классификации данных газоаналитического обследования дыхательной системы // *Вестник Томского государственного университета. Управление, вычислительная техника и информатика*. 2024. № 69. С. 112–123. doi: 10.17223/19988605/69/12
15. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift // *Proc. of the 32nd International Conference on Machine Learning*. 2015. P. 448–456.
16. Santurkar S., Tsipras D., Ilyas A., Madry A. How Does Batch Normalization Help Optimization? // *Advances in Neural Information Processing Systems 31 (NeurIPS 2018)*. Montréal, Canada, 3–8 December 2018. doi: 10.48550/arXiv.1805.11604
17. Kim D., Kim W., Kim S. Tanh Works Better with Asymmetry // *Advances in Neural Information Processing Systems 36 (NeurIPS 2023)*. Main Conference Track.
18. Philipp G., Song D., Carbonell J.G. The exploding gradient problem demystified - definition, prevalence, impact, origin, tradeoffs, and solutions. 2017. doi: 10.48550/arXiv:1712.05577
19. Dozat T. Incorporating Nesterov Momentum into Adam // *Proceedings of the 4th International Conference on Learning Representations, Workshop Track*. San Juan, Puerto Rico, 2–4 May 2016. P. 1–4.
20. Дель И.В., Старченко А.В. Использование методов нейросетевого моделирования для прогнозирования качества атмосферного воздуха // *Вестник Томского государственного университета. Управление, вычислительная техника и информатика*. 2023. № 65. С. 15–24. doi: 10.17223/19988605/65/2
21. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. Cambridge, MA: MIT Press, 2016. 800 p.

References

1. Mohammadzaheri, M., Chen, L. & Grainger, S. (2012) A Critical Review of the Most Popular Types of Neuro Control. *Asian Journal of Control*. 14(1). pp. 1–11. doi: 10.1002/asjc.449
2. Chernodub, A.N. & Dzyuba, D.A. (2011) Obzor metodov neyropravleniya [Neurocontrol methods review]. *Problemy programmirovaniya*. 2. pp. 79–94.

3. Bonassi, F., Farina, M., Xie, J. & Scattolini, R. (2022) On Recurrent Neural Networks for learning-based control: recent results and ideas for future developments. *Journal of Process Control*. 114. pp. 92–104. doi: 10.1016/j.jprocont.2022.04.011
4. Chinnam, R.B. & Kolarik, W.J. (1997) Neural network-based quality controllers for manufacturing systems. *International Journal of Production Research*. 35(9). pp. 2601–2620. doi: 10.1080/002075497194688
5. Nouri, K., Dhaouadi, R. & Braiek, N.B. (2006) Nonlinear speed control of a dc motor drive system with online trained recurrent neural network. *9th IEEE International Workshop on Advanced Motion Control*. Istanbul, Turkey. pp. 704–708. doi: 10.1109/amc.2006.1631746
6. Velchenko, A.A., Pavlyukovets, S.A., Radkevich, A.A. & Ibrahim, A.K. (2025) Energoeffektivnoe neyrosetevoe upravlenie beskollektornym dvigatelem postoyannogo toka [Energy-Efficient Neural Network Control of a Brushless DC Motor]. *Energetika. Izvestiya vysshikh uchebnykh zavedeniy i energeticheskikh ob"edineniy SNG*. 68(1). pp. 45–57. doi: 10.21122/1029-7448-2025-68-1-45-57
7. Nouri, K., Dhaouadi, R. & Braiek, N.B. (2008) Adaptive Control of a Nonlinear DC Motor Drive Using Recurrent Neural Networks. *Applied Soft Computing*. 8. pp. 371–382.
8. Rubaai, A. & Young, P. (2016) Hardware/Software Implementation of Fuzzy-Neural-Network Self-Learning Control Methods for Brushless DC Motor Drives. *IEEE Transactions on Industry Applications*. 52(1). pp. 414–424. doi: 10.1109/tia.2015.2468191
9. Nouri, K., Dhaouadi, R. & Braiek, N.B. (2008) Adaptive control of a nonlinear dc motor drive using recurrent neural networks. *Applied Soft Computing*. 8(1). pp. 371–382. doi: 10.1016/j.asoc.2007.03.002
10. Kaminski, M. & Tarczewski, T. (2023) Neural Network Applications in Electrical Drives—Trends in Control. *Estimation, Diagnostics, and Construction. Energies*. 16(11). Art. 4441. doi: 10.3390/en16114441
11. Lee, Y.-S. & Jang, D.-W. (2021) Optimization of Neural Network-Based Self-Tuning PID Controllers for Second Order Mechanical Systems. *Applied Sciences*. 11(17). Art. 8002. doi: 10.3390/app11178002
12. Schmidt, I.A. & Dadenkov, D.A. (2024) Ispol'zovanie iskusstvennoy neyronnoy seti v elektromekhanicheskoy sisteme regulirovaniya skorosti dvigatelya postoyannogo toka [Use of an Artificial Neural Network in an Electromechanical Speed Control System of a DC Motor]. *Elektrotehnika*. 11. pp. 26–32.
13. Fleming, P.J. & Purshouse, R.C. (2002) Evolutionary algorithms in control systems engineering: a survey. *Control Engineering Practice*. 10(11). pp. 1223–1241. doi: 10.1016/s0967-0661(02)00081-3
14. Obkhodskiy, A.V., Kulbakin, D.E., Obkhodskaya, E.V., Popov, A.S., Rodionov, E.O., Sachkov, V.I., Chernov, V.I. & Choyznov, E.L. (2024) Neural network classification software for the gas analytical survey data of respiratory system. *Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel'naya tekhnika i informatika – Tomsk State University Journal of Control and Computer Science*. 69. pp. 112–123. doi: 10.17223/19988605/69/12
15. Ioffe, S. & Szegedy, C. (2015) Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *Proceedings of the 32nd International Conference on Machine Learning*. pp. 448–456.
16. Santurkar, S., Tsipras, D., Ilyas, A. & Madry, A. (2018) How Does Batch Normalization Help Optimization? *Advances in Neural Information Processing Systems 31 (NeurIPS 2018)*. Montréal, Canada, December 3–8, 2018.
17. Kim, D., Kim, W. & Kim, S. (2023) Tanh Works Better with Asymmetry. *Advances in Neural Information Processing Systems 36 (NeurIPS 2023)*. Main Conference Track.
18. Philipp, G., Song, D. & Carbonell, J.G. (2017) The exploding gradient problem demystified - definition, prevalence, impact, origin, tradeoffs, and solutions. *arXiv preprint*. arXiv:1712.05577.
19. Dozat, T. (2016) Incorporating Nesterov Momentum into Adam. *Proc. of the 4th International Conference on Learning Representations, Workshop Track*. San Juan, Puerto Rico, May 2-4, 2016. pp. 1–4.
20. Del, I.V. & Starchenko, A.V. (2023) Using neural network modeling for air quality prediction. *Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel'naya tekhnika i informatika – Tomsk State University Journal of Control and Computer Science*. 65. pp. 15–24. doi: 10.17223/19988605/65/2
21. Goodfellow, I., Bengio, Y. & Courville, A. (2016) *Deep Learning*. Cambridge, MA: MIT Press.

Информация об авторах:

Шмидт Игорь Альбертович – кандидат технических наук, доцент кафедры микропроцессорных средств автоматизации Пермского национального исследовательского политехнического университета (Пермь, Россия). E-mail: shmidt@pstu.ru

Попов Илья Алексеевич – магистрант кафедры микропроцессорных средств автоматизации Пермского национального исследовательского политехнического университета (Пермь, Россия). E-mail: ilya.popov2801@mail.ru

Жуков Дмитрий Романович – магистрант кафедры микропроцессорных средств автоматизации Пермского национального исследовательского политехнического университета (Пермь, Россия). E-mail: dimonzhukov1503@gmail.com

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Information about the authors:

Schmidt Igor A. (Candidate of Technical Sciences, Associate Professor, Department of Microprocessor Automation Tools, Perm National Research Polytechnic University, Perm, Russian Federation). E-mail: shmidt@pstu.ru

Popov Ilya Alekseevich (Master's Student, Department of Microprocessor Automation Tools, Perm National Research Polytechnic University, Perm, Russian Federation). E-mail: ilya.popov2801@mail.ru

Zhukov Dmitry R. (Master's Student, Department of Microprocessor Automation Tools, Perm National Research Polytechnic University, Perm, Russian Federation). E-mail: dimonzhukov1503@gmail.com

Contribution of the authors: the authors contributed equally to this article. The authors declare no conflicts of interests.

Поступила в редакцию 06.11.2025; принята к публикации 05.03.2026

Received 06.11.2025; accepted for publication 05.03.2026