

УДК 629.4

Использование методов машинного обучения для решения задачи энергооптимального движения поезда

С. Г. Истомин, К. И. Доманов, А. П. Шатохин, И. Н. Денисов, А. А. Лаврухин

Омский государственный университет путей сообщения, Российская Федерация, 644046, Омск, Маркса пр., 35

Для цитирования: *Истомин С. Г., Доманов К. И., Шатохин А. П., Денисов И. Н., Лаврухин А. А.* Использование методов машинного обучения для решения задачи энергооптимального движения поезда // Известия Петербургского университета путей сообщения. — СПб.: ПГУПС, 2025. — Т. 22. — Вып. 1. — С. 75–84. DOI: 10.20295/1815-588X-2025-1-75-84

Аннотация

Цель: Выбрать и обосновать методы и алгоритмы машинного обучения с целью построения динамических моделей энергооптимального движения локомотива с поездом в режиме реального времени. Ранее был определен уровень фактического использования систем автоматизации вождения грузовых поездов магистральными грузовыми электровозами постоянного тока, а также выявлены факторы, влияющие на энергооптимальный график исполненного движения поездов. Настоящая статья посвящена новому этапу разработки инновационной технологии по автоматизированному управлению локомотивом с поездом в рамках выполнения проекта по гранту ОАО «РЖД» для молодых ученых на проведение научных исследований, направленных на создание новой техники и технологий для применения на железнодорожном транспорте. **Методы:** Использовались методы оптимизации в машинном обучении с применением программного обеспечения, предназначенного для моделирования нелинейных динамических систем. **Результаты:** Было установлено, что для решения задачи определения оптимальной позиции контроллера машиниста путем использования результатов обучений рекуррентной нейронной сети является метод Левенберга — Марквардта. Получены графические зависимости гистограмм ошибок и изменения суммарной среднеквадратической ошибки в процессе обучения искусственной нейронной сети. **Практическая значимость:** Результаты работы могут быть использованы при разработке аппаратно-программных комплексов, с применением методов и алгоритмов искусственного интеллекта, направленных на повышение энергетической эффективности перевозочного процесса.

Ключевые слова: Машинное обучение, локомотив, искусственный интеллект, автоматизированное управление, энергооптимальный график движения, энергетическая эффективность.

Введение

Повышение энергетической эффективности перевозочного процесса является одним из приоритетных направлений развития компании ОАО «РЖД» [1]. Поэтому разработка методов и алгоритмов энергооптимального движения поездов на всех железнодорожных полигонах России является актуальной задачей.

В этой связи разные коллективы ученых ведут исследования в данной области с использованием классических методов теории тяги поездов, однако в условиях развития систем цифровизации и современных локомотивов перспективным является применение для исполнения данных задач методов и алгоритмов машинного обучения с использованием искусственного интеллекта.

Исследователи из АО «НИИАС» и TÜV Rheinland (Кельн, Германия) в своей работе [2] описали возможность применения графового Марковского метода расчета безопасности и надежности сложных систем при использовании в технологиях автоведения поездов путем повышения эффективности машинного обучения программных средств технического зрения. В работе [3] исследователя из Петербургского государственного университета путей сообщения Императора Александра I определено, что с помощью применения машинного обучения можно повысить точность расчета технико-экономических моделей высокоскоростных магистралей, а в дальнейшем сократить затраты на эксплуатацию подвижного состава. Коллектив ученых из Нидерландов в своем исследовании [4] описали существующие алгоритмы для энергоэффективного управления поездами и составления расписания с использованием методов машинного обучения. Китайские ученые в своих исследованиях [5–7] задачу оптимального планирования траектории движения поезда рассмотрели как задачу смешанного целочисленного линейного программирования путем аппроксимации нелинейных членов заданных кусочно-аффинными функциями. Американские ученые в работе [8] предложили новую модель динамического контроля скоростного режима ведения поездов в стохастической транспортной сети для повышения энергоэффективности перевозочного процесса.

Данная статья представляет собой изложение второго этапа разработки технологии построения динамических моделей энергооптимального движения локомотива в режиме реального времени для интеллектуально-адаптивной системы поддержки управления подвижным составом с применением методов и алгоритмов машинного обучения и искусственного интеллекта. Первый этап разработки новой технологии изложен в [9], где определен уровень фактического использо-

вания систем автоматизации вождения грузовых поездов на участках Урало-Сибирского железнодорожного полигона и его влияние на энергооптимальный график исполненного движения поездов, а также приведен анализ влияния современных тенденций в области энергосбережения и улучшения эффективности использования тяговых энергетических ресурсов на железнодорожном транспорте на тягу поездов, который показал, что в настоящее время малоисследованными остаются режимы ведения поезда, построенные на методах и алгоритмах машинного обучения и искусственного интеллекта.

В настоящей статье авторами с использованием программного обеспечения Matlab выполнено компьютерное моделирование режимов работы (тяга, выбег, электрическое торможение, пневматическое торможение) магистрального грузового электровоза серии 2ЭС6 «Синара» на участке Входная — Иртышское Западно-Сибирской железной дороги. В качестве исходных данных для моделирования использовались следующие данные реальных поездов из системы РПДА-Г, производства компании АВП «Технология» (более 35 000 поездов за 2023 год): профиль пути элемента железнодорожного участка, скорость движения поезда на заданном элементе пути, напряжение на токоприемнике, сила тяги, ток электровоза (на токоприемнике), мощность электровоза, масса состава, позиция контроллера машиниста (текущая и предыдущая), время прохода элемента пути железнодорожного участка.

Исследуемые алгоритмы машинного обучения

С теоретической точки зрения искусственный интеллект — это наука, позволяющая научить машины думать и принимать решения, а машинное обучение является его разделом. На сегодняшний день существует множество алгоритмов машинного обучения для решения транспорт-

ных задач. В качестве примера можно привести несколько наиболее часто используемых:

- линейная регрессия;
- метод опорных векторов;
- метод k -ближайших соседей;
- деревья решений;
- ансамбли;
- метод k -средних.

Стоит отметить, что данная классификация может быть сведена к трем основным методам [10]:

1) контролируемое обучение (алгоритмы строят свой прогноз на основе выборок, в которых мы знаем, как выглядит результат);

2) неконтролируемое обучение (метод используется, если неизвестен конечный результат);

3) обучение с подкреплением (при решении задачи алгоритм получает отзыв о правильном или неправильном решении, накапливая тем самым историю подкрепления).

Для решения задачи энергооптимального движения локомотива важным является выбор алгоритма оптимизации, который является основой

машинного обучения. К основным достоинствам такого выбора можно отнести то, что оптимизация позволяет определить наилучшее решение из различных возможных.

Алгоритмы оптимизации делятся на два основных класса: алгоритмы первого порядка и второго порядка.

К алгоритмам первого порядка можно отнести: градиентный спуск; методы стохастической оптимизации; эволюционные алгоритмы; мета-эвристическая оптимизация; алгоритмы роевого интеллекта; гиперпараметрическая оптимизация; оптимизация в глубоком обучении.

К алгоритмам второго порядка относят: метод Ньютона и квази-ньютоновские методы; ограниченную оптимизацию; Байесовскую оптимизацию.

Выбирая оптимальный алгоритм для последующего обучения нейронной сети, необходимо учитывать предыдущие результаты ее обучения. Для используемой в настоящем исследовании рекуррентной нейронной сети (рис. 1) показателями качественной аппроксимации будут являться

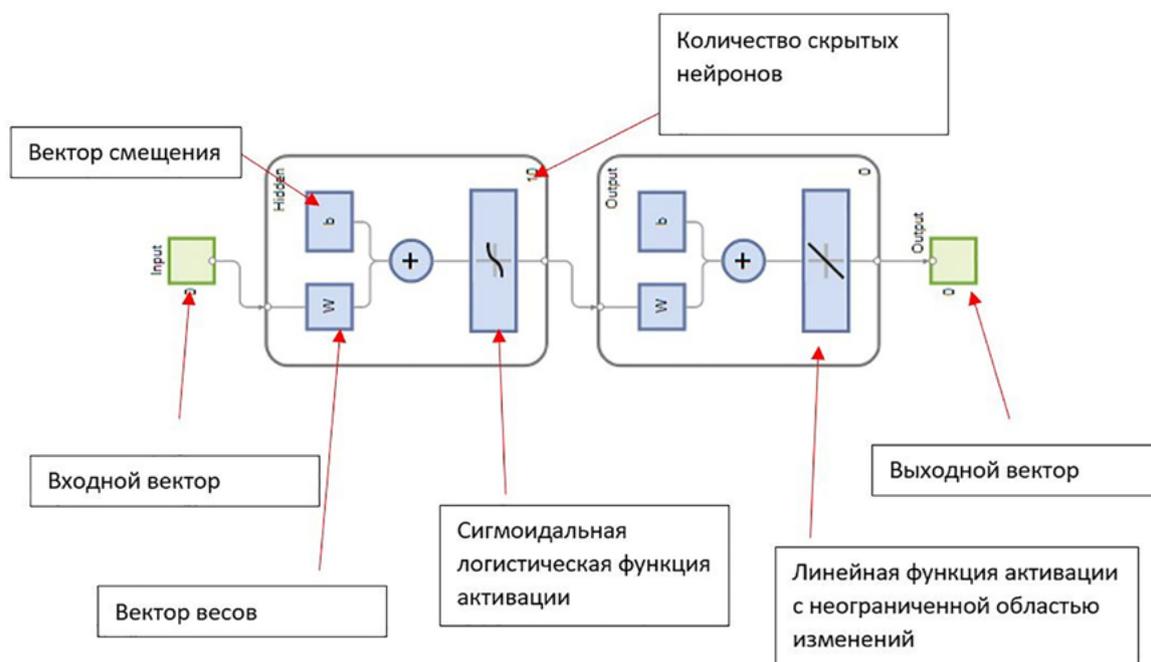


Рис. 1. Сеть прямого распространения

затраченное время на обучение, схожесть проверочного и тестового наборов по характеристикам, отсутствие переобучения, величина регрессии, а также низкая суммарная среднеквадратическая ошибка между входами сети прямого распространения и целевыми значениями:

$$F = mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2,$$

где F — суммарная среднеквадратическая ошибка;
 N — размер выборки (количество значений данных);

t — фактическое (истинное) значение данных;
 a — прогнозируемое (предсказанное) значение данных;

e — ошибка (разность между желаемым и реальным сигналом), безразмерная величина, это разность при сравнении входного и выходного вектора которая должна соответствовать целевому вектору.

В качестве алгоритмов обучения в работе были исследованы и апробированы следующие методы: Левенберга — Марквардта (Levenberg — Marquardt); связанных градиентов Полака — Рибера (Polak — Ribiere); связанных градиентов Флетчера — Пауэлла (Fletcher — Powell); связанных градиентов Пауэлла — Била (Powell — Beale); тренировка сети с использованием квази-ньютоновского метода BFGS; регуляризация Bayesian; градиентного спуска; градиентного спуска с адаптивным обучением; градиентного спуска с учетом моментов; градиентного спуска с учетом моментов и с адаптивным обучением; одноступенчатый метод секущих; упругого обратного распространения; последовательных приращений.

Обучение нейронной сети и определение суммарной среднеквадратической ошибки

Для обучения использовались входные вектора данных, состоящих из параметров, полученных по результатам поездок ведения поездов — про-

филь пути элемента железнодорожного участка, скорость движения поезда на заданном элементе пути, напряжение на токоприемнике, сила тяги, ток электровоза (на токоприемнике), мощность электровоза, масса состава, позиция контроллера машиниста (текущая и предыдущая), время прохода элемента пути железнодорожного участка [9].

Выходным вектором по результатам обучения была принята позиция контроллера машиниста.

Остановка обучения проводилась после того, как значение функции ошибки нейронной сети возрастала шесть эпох подряд.

Рассмотрим более подробно результаты моделирования данных с РПДА-Г с использованием метода Левенберга — Марквардта и метода градиентного спуска с адаптивным обучением и выявим подходящий алгоритм оптимизации с точки зрения затраченного времени обучения, среднеквадратической ошибки и кучности значений на выходе к наклонной прямой для решения задачи энергооптимального движения поезда. Результаты моделирования для остальных методов авторы не приводят ввиду ограниченности объема публикации. Стоит отметить, что данные методы показали худшие результаты.

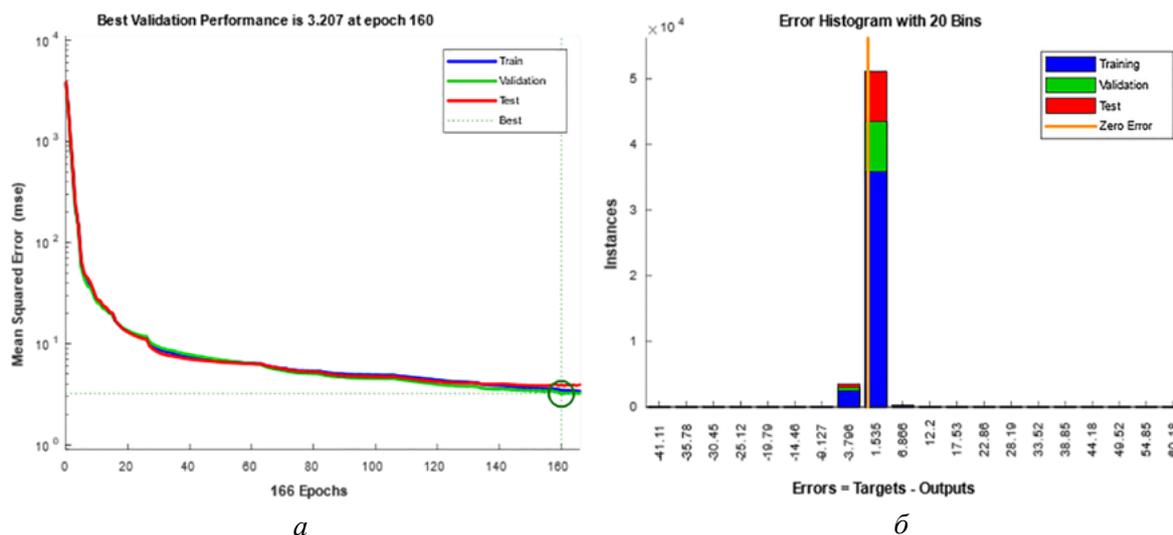
Метод Левенберга — Марквардта (Levenberg — Marquardt) является нелинейным методом наименьших квадратов. Он представляет собой симбиоз таких методов, как метод наискорейшего спуска, метод Ньютона и метод Гаусса — Ньютона [11]. К достоинствам исследуемого метода можно отнести:

- наибольшую устойчивость среди проанализированных методов;
- наибольшие шансы найти глобальный экстремум;
- высокую скорость сходимости результатов моделирования.

В табл. 1 приведены исходные параметры для проведения обучения нейронной сети. Для этого было использовано специальное программное

Таблица 1. Параметрические данные обучения нейронной сети с использованием метода Левенберга — Марквардта

Параметр	Начальное значение	Значение останковки бучения	Целевое значение
Эпоха	0	166	1000
Время обучения	—	00:02:15	—
Погрешность сети	3.8e+03	3.4	0
Градиент	1.47e+04	18	1e-07
Ми	0.001	0.001	1e+10
Проверка валидации	0	6	6

Рис. 2. Изменение ошибки mse (а) в процессе обучения искусственной нейронной сети и гистограмма ошибок (б) методом Левенберга — Марквардта

обеспечение MathWorks. Результаты показали, что на обучение затрачено 2 минуты 15 секунд, минимальное значение функции ошибки получено на 160 эпохе, после чего на 166 эпохе было остановлено обучение ввиду возрастания функции ошибки.

С теоретической точки зрения важно отметить (рис. 2) минимальное значение mse , равное 3,207 (а). Ошибка проверочного (Validation) и тестового (Test) набора имеет схожий характер, то есть отсутствует переобучение сети. Гистограмма ошибок (б) показывает незначительный разброс данных по тестовой и проверочной выборке, что свидетельствует о высокой доли вероятности прогнозирования исходных данных.

Наряду с вышесказанным необходимо обратить внимание (рис. 3) на итоговое состояние

обучения сети и полученные числовые характеристики регрессии для наборов данных (б), значения которых близки к 1. Это свидетельствует о том, что нейронная сеть хорошо аппроксимировала искомую зависимость. Стоит отметить и кучность значений на выходе к наклонной прямой, что также подтверждает удовлетворительное качество обучения.

В свою очередь, проведя обучение нейронной сети с использованием метода градиентного спуска с адаптивным обучением, выявлено, что не в каждой ситуации результаты показывают сходимость быстрее обычного градиентного спуска, однако исследуемый метод гораздо стабильнее минимизирует функцию потерь. В табл. 2 приведены исходные параметры для проведения обучения нейронной сети методом градиентного спу-

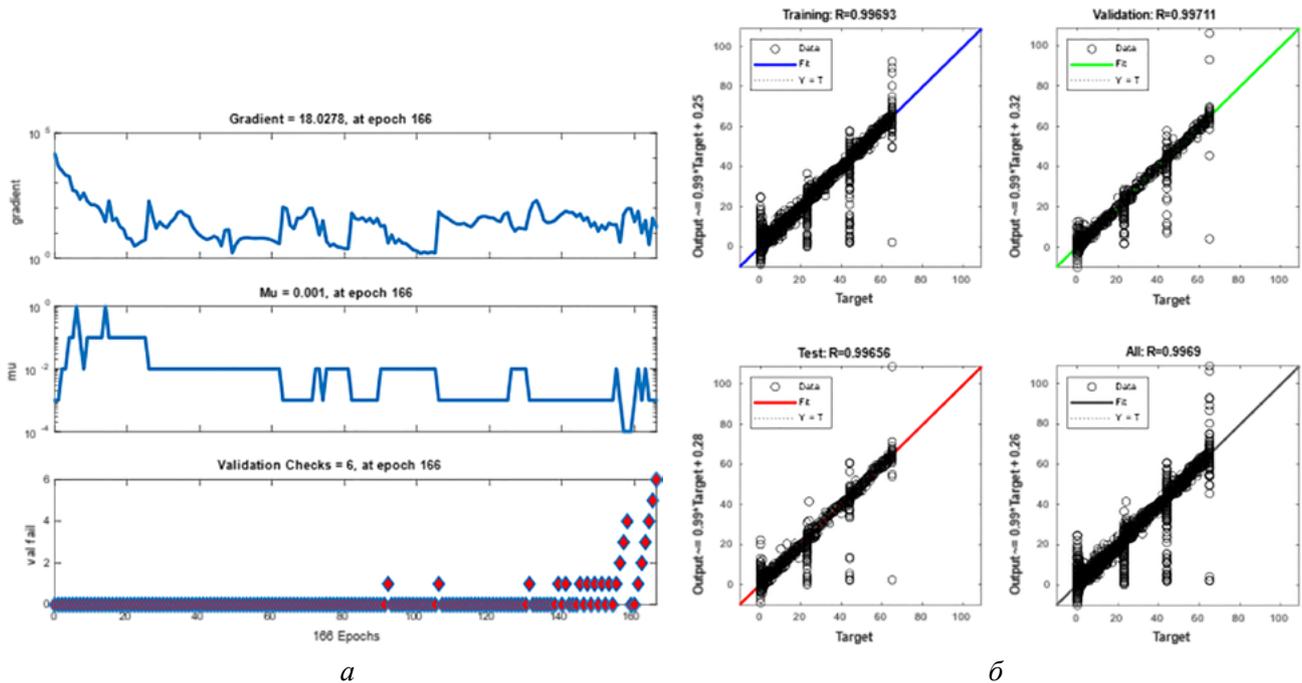


Рис. 3. Состояние обучения нейронной сети (а) и линейная регрессия (б) методом Левенберга — Марквардта

Таблица 2. Параметрические данные обучения нейронной сети с использованием метода градиентного спуска с адаптивным обучением

Параметр	Начальное значение	Значение останковки бучения	Целевое значение
Эпоха	0	84	1000
Время обучения	—	00:00:17	—
Погрешность сети	432	114	0
Градиент	5.12e+03	1.29e+03	1e-05
Му	0	6	6
Проверка валидации	0	84	1000

ска с адаптивным обучением. Из таблицы видно, что на обучение затрачено 17 секунд, минимальное значение функции ошибки получено на 78 эпохе, после чего на 84 эпохе было остановлено обучение ввиду возрастания функции ошибки.

Следует обратить внимание на то (рис. 4), что по результатам обучения минимальное значение mse получилось равным 115,366 (а), что в значительной степени больше, чем в методе Левенберга — Марквардта. Ошибка проверочного (Validation) и тестового (Test) набора имеет

схожий характер, отсутствует переобучение сети. Гистограмма ошибок (б) показывает разброс данных по тестовой и проверочной выборке больше, чем в методе Левенберга — Марквардта.

Наиболее важным представляется меньшая кучность значений на выходе к наклонной прямой в сравнении с методом Левенберга — Марквардта. Результаты моделирования представлены на рис. 5.

По результатам имитационного моделирования определено, что наиболее подходящим

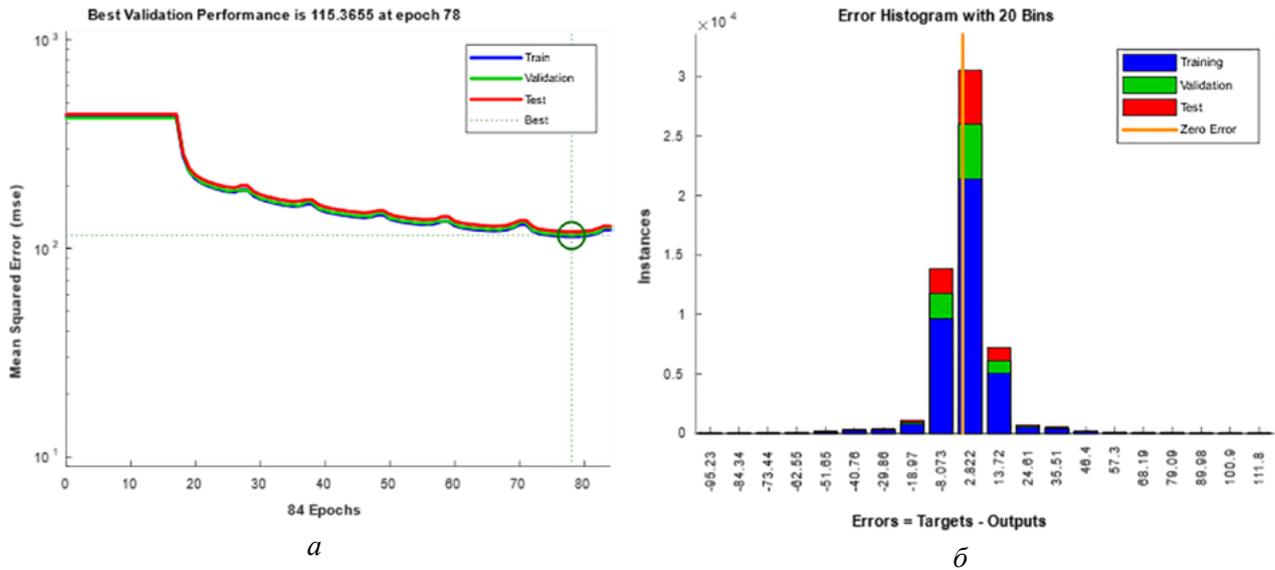


Рис. 4. Изменение ошибки *mse* (а) в процессе обучения искусственной нейронной сети и гистограмма ошибок (б) методом градиентного спуска с адаптивным обучением

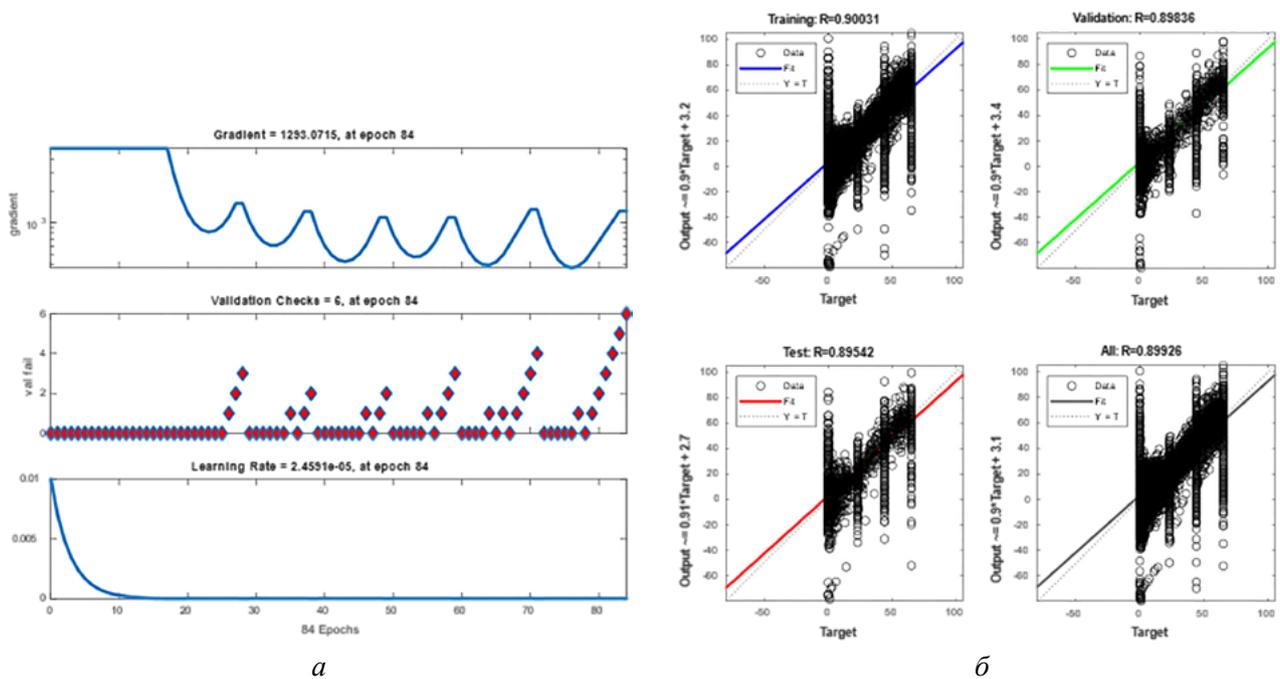


Рис. 5. Состояние обучения нейронной сети (а) и линейная регрессия (б) методом градиентного спуска с адаптивным обучением

алгоритмом оптимизации для решения задачи определения оптимальной позиции контроллера машиниста с точки зрения затраченного времени обучения, среднеквадратической ошибки и кучности значений на выходе к наклонной прямой является метод Левенберга — Марквардта.

Заключение

В результате проведенного исследования получены данные, которые подтверждают высокую эффективность применения нейронных сетей для определения наиболее энергоэффективной позиции контроллера машиниста, ввиду кучно-

сти значений вдоль прямой квадрата регрессии и низкого количества выбросов значений по результатам обучения нейронной сети.

Скорость вычислений и достигаемая точность подтверждает возможность создания интеллектуально-адаптивной системы поддержки управления тяговым подвижным составом.

По результатам моделирования ошибка определения позиции контроллера в зависимости от метода оптимизации при обучении нейронной сети варьировалась от 2,19 до 15 814,94, что характеризует рассеивание значений случайной величины относительно ее математического ожидания.

Время решения задачи определения позиции контроллера машиниста составляла от 5 секунд до 27 минут — данное заключение носит предварительный характер, так как способность компьютера обрабатывать массив данных зависит от технических характеристик его процессора.

Выявлено, что для более точного определения величины тока и позиции контроллера машиниста при проектировании сети наиболее важным является подготовка данных для обучения.

Благодарности

Исследование выполнено за счет гранта ОАО «РЖД» для молодых ученых на проведение научных исследований, направленных на создание новой техники и технологий для применения на железнодорожном транспорте, № 5549635 от 31.01.2024.

Список источников

1. Энергетическая стратегия холдинга «Российские железные дороги» на период до 2020 года и на перспективу до 2030 года / Утверждена распоряжением ОАО «РЖД» от 14 декабря 2016 г. № 2537р. — М., 2016. — 76 с.
2. Шубинский И. Б. К оценке безопасности системы автоведения поездов / И. Б. Шубинский, Х. Шебе, Е. Н. Розенберг // Надежность. — 2021. — Т. 21. —

№ 4. — С. 31–37. — DOI: 10.21683/1729-2646-2021-21-4-31-37.

3. Сычугов А. Н. Применение машинного обучения для анализа технических характеристик и параметров эксплуатируемого подвижного состава на высокоскоростных железнодорожных магистралях / А. Н. Сычугов // Бюллетень результатов научных исследований. — 2023. — № 2. — С. 171–180. — DOI: 10.20295/2223-9987-2023-2-171-180.

4. Scheepmaker G. M. Review of energy-efficient train control and timetabling / G. M. Scheepmaker, R. M. P. Goverde, L. G. Kroon // European Journal of Operational Research. — 2017. — Iss. 257(2). — Pp. 355–76. URL: <http://dx.doi.org/10.1016/j.ejor.2016.09.044>.

5. Wang Y. Optimal trajectory planning for trains — A pseudospectral method and a mixed integer linear programming approach / Y. Wang, B. De Schutter, T. J. J. van den Boom et al. // Transportation Research Part C: Emerging Technologies. — 2013. — Vol. 29. — Pp. 97–114. — URL: <http://dx.doi.org/10.1016/j.trc.2013.01.007>.

6. Wang X. Intelligent operation of heavy haul train with data imbalance: A machine learning method / X. Wang, S. Li, T. Tang et al. // Knowledge-Based Systems. — 2019. — Vol. 163. — Pp. 36–50. — URL: <http://dx.doi.org/10.1016/j.knosys.2018.08.015>.

7. Zhang C. Y. Data-driven train operation models based on data mining and driving experience for the diesel-electric locomotive / C. Y. Zhang, D. Chen, J. Yin et al. // Advanced Engineering Informatics. — 2016. — Vol. 30(3). Pp. 553–63. — URL: <http://dx.doi.org/10.1016/j.aei.2016.07.004>.

8. Zhu F. Accounting for dynamic speed limit control in a stochastic traffic environment: A reinforcement learning approach / F. Zhu, S. V. Ukkusuri // Transportation Research Part C: Emerging Technologies. — 2014. — Vol. 41. — Pp. 30–47. — URL: <http://dx.doi.org/10.1016/j.trc.2014.01.014>.

9. Истомина С. Г. Текущее состояние и перспективы развития систем энергооптимального управления электровозами 2ЭС6 / С. Г. Истомина, К. И. Доманов, А. П. Шатохин и др. // Вестник Научно-исследовательского института железнодорожного транспорта (Вестник ВНИИЖТ). — 2024. — Т. 83. — № 3. — С. 215–229.

10. Акатъев Я. А. Анализ особенностей алгоритмов машинного обучения в автоматизированных системах вождения / Я. А. Акатъев, А. Р. Латыпов // E-Scio. — 2022. — № 1(64). — С. 641–655.

11. Chopra D. Introduction to Machine Learning / D. Chopra, R. Khurana // Introduction to Machine Learning with Python. — 2023. — Vol. 28. — Pp. 15–29. — URL: <http://dx.doi.org/10.2174/9789815124422123010004>.

Дата поступления: 20.11.2024

Решение о публикации: 20.01.2025

Контактная информация:

ИСТОМИН Станислав Геннадьевич — канд. техн. наук, доц.; istomin_sg@mail.ru

ДОМАНОВ Кирилл Иванович — канд. техн. наук, доц.; dki35@ya.ru

ШАТОХИН Андрей Петрович — канд. техн. наук, директор; shatohin_ap@mail.ru

ДЕНИСОВ Илья Николаевич — зав. лабораторией; idenisov89@mail.ru

ЛАВРУХИН Андрей Александрович — канд. техн. наук, доц.; a.a.lavrukhin@ya.ru

The Use of Machine Learning Methods to Solve the Problem of Energy-Efficient Train Movement

S. G. Istomin, K. I. Domanov, A. P. Shatokhin, I. N. Denisov, A. A. Lavrukhin

Omsk State Transport University, Russian Federation, 35, Marks pr., Omsk, 644046, Russian Federation

For citation: Istomin S. G., Domanov K. I., Shatokhin A. P., Denisov I. N., Lavrukhin A. A. The Use of Machine Learning Methods to Solve the Problem of Energy-Efficient Train Movement // *Proceedings of Petersburg State Transport University*, 2025, vol. 22, iss. 1, pp. 75–84. (In Russian) DOI: 10.20295/2223-9987-2025-1-75-84

Summary

Purpose: To select and verify methods and algorithms of machine learning to build dynamic models of a train energy-efficient movement in real time. Earlier, the use of DC electric locomotives for driving freight trains was assessed and the factors influencing the energy-efficient train movement were identified. This paper is devoted to the latest innovations in the field of automated train control within the framework of the JSC “Russian Railways” grant project for young scientists to carry out scientific research aimed at creating new equipment and technologies for railway transport. **Methods:** Optimization methods for machine learning were applied using model nonlinear dynamic systems. **Results:** The Levenberg-Marquardt method has been found most appropriate for determining the optimal position of the train driver controller by using recurrent neural network training. Graphical dependences of error histograms and total mean square error (MSE) variations in the process of artificial neural network training have been obtained. **Practical significance:** The results of the research can be used in the development of hardware and software systems using artificial intelligence methods and algorithms aimed at energy-efficiency improvement in transportation process.

Keywords: Machine learning, locomotive, artificial intelligence, automated control, energy-optimal schedule, energy efficiency.

Acknowledgments

The research was carried out at the expense of a grant from JSC Russian Railways for young scientists to conduct scientific research aimed at creating new equipment and technologies for use in railway transport No. 5549635 dated 01/31/2024.

References

1. *Energeticheskaya strategiya kholdinga "Rossiyskie zheleznye dorogi" na period do 2020 goda i na perspektivu do 2030 goda. Utverzhdena rasporyazheniem OAO "RZhD" ot 14 dekabrya 2016 g. № 2537r* [Energy strategy of the Russian Railways holding company for the period up to 2020 and for the future up to 2030. Approved by the order of Russian Railways dated December 14, 2016 № 2537r]. Moscow, 2016, 76 p. (In Russian)
2. Shubinskiy I. B., Shebe Kh., Rozenberg E. N. K otsenke bezopasnosti sistemy avtovedeniya poezdov [On the safety assessment of the automatic train control system]. *Nadezhnost'* [Reliability]. 2021, vol. 21, Iss. 4, pp. 31–37. DOI: 10.21683/1729-2646-2021-21-4-31-37. (In Russian)
3. Sychugov A. N. Primenenie mashinnogo obucheniya dlya analiza tekhnicheskikh kharakteristik i parametrov ekspluatiruemogo podvizhnogo sostava na vysokoskorostnykh zheleznodorozhnykh magistralyakh [Application of machine learning for the analysis of technical characteristics and parameters of operating rolling stock on high-speed railways]. *Byulleten' rezul'tatov nauchnykh issledovaniy* [Bulletin of scientific research results]. 2023, Iss. 2, pp. 171–180. DOI: 10.20295/2223-9987-2023-2-171-180. (In Russian)
4. Scheepmaker G. M., Goverde R. M. P., Kroon L. G. Review of energy-efficient train control and timetabling. *European Journal of Operational Research*, 2017, Iss. 257(2), pp. 355–76. Available at: <http://dx.doi.org/10.1016/j.ejor.2016.09.044>.
5. Wang Y., Schutter B. De, van den Boom T. J. J. et al. Optimal trajectory planning for trains — A pseudospectral method and a mixed integer linear programming approach. *Transportation Research Part C: Emerging Technologies*, 2013, vol. 29, pp. 97–114. Available at: <http://dx.doi.org/10.1016/j.trc.2013.01.007>.
6. Wang X., Li S., Tang T. et al. Intelligent operation of heavy haul train with data imbalance: A machine learning method. *Knowledge-Based Systems*, 2019, vol. 163, pp. 36–50. Available at: <http://dx.doi.org/10.1016/j.knosys.2018.08.015>.
7. Zhang C. Y., Chen D., Yin J. et al. Data-driven train operation models based on data mining and driving experience for the diesel-electric locomotive. *Advanced Engineering Informatics*, 2016, vol. 30(3), pp. 553–63. Available at: <http://dx.doi.org/10.1016/j.aei.2016.07.004>.
8. Zhu F., Ukkusuri S. V. Accounting for dynamic speed limit control in a stochastic traffic environment: A reinforcement learning approach. *Transportation Research Part C: Emerging Technologies*, 2014, vol. 41, pp. 30–47. Available at: <http://dx.doi.org/10.1016/j.trc.2014.01.014>.
9. Istomin S. G., Domanov K. I., Shatokhin A. P. et al. Tekushchee sostoyanie i perspektivy razvitiya sistem energooptimal'nogo upravleniya elektrovozami 2ES6 [Current state and development prospects of energy-optimal control systems for 2ES6 electric locomotives]. *Vestnik Nauchno-issledovatel'skogo instituta zheleznodorozhnogo transporta (Vestnik VNIIZhT)* [Bulletin of the Research Institute of Railway Transport (Vestnik VNIIZhT)]. 2024, vol. 83, Iss. 3, pp. 215–229. (In Russian)
10. Akat'ev Ya. A., Latypov A. R. *Analiz osobennostey algoritmov mashinnogo obucheniya v avtomatizirovannykh sistemakh vozhdeniya* [Analysis of machine learning algorithms features in automated driving systems]. *E-Scio*, 2022, Iss. 1(64), pp. 641–655. (In Russian)
11. Chopra D., Khurana R. Introduction to Machine Learning. *Introduction to Machine Learning with Python*, 2023, vol. 28, pp. 15–29. Available at: <http://dx.doi.org/10.2174/9789815124422123010004>.

Received: November 20, 2024

Accepted: January 20, 2025

Author's information:

Stanislav G. ISTOMIN — PhD in Engineering, Associate Professor; istomin_sg@mail.ru

Kirill I. DOMANOV — PhD in Engineering, Associate Professor; dki35@ya.ru

Andrey P. SHATOKHIN — PhD in Engineering, Director; shatohin_ap@mail.ru

Il'ya N. DENISOV — Head of Laboratories; idenisov89@mail.ru

Andrey A. LAVRUHIN — PhD in Engineering, Associate Professor; a.a.lavrukhin@ya.ru