

Метод построения адаптивного субоптимального стационарного регулятора движения поезда на основе искусственных нейронных сетей

С. В. МАЛАХОВ, М. Ю. КАПУСТИН

Федеральное государственное автономное образовательное учреждение высшего образования «Российский университет транспорта» (ФГАУ ВО «РУТ» (МИИТ)), Москва, 127055, Россия

Аннотация. В статье рассмотрена современная методология выполнения синтеза субоптимального регулятора движения поезда с целью энергосбережения. Существующие методы оптимального управления тягой обладают рядом недостатков, главный из которых — отсутствие непосредственного использования в программе управления данных, полученных во время движения поезда. Математические модели, применяемые для решения оптимальной задачи, могут быть использованы корректно только в случае достаточной адекватности. Проверка на адекватность не является частью известных методов теории оптимального управления. Для устранения такого недостатка предлагается использовать метод оптимальных (субоптимальных) тяговых расчетов на основе искусственных нейронных сетей. Он позволяет повысить точность тяговых расчетов, что особенно важно в аспекте рассмотрения экономии энергозатрат, при этом сократив потребность в вычислительных мощностях. При использовании данного метода можно не только достичь результатов, близких к классическому методу Беллмана, но и проводить обучение или верификацию сети на основе зарегистрированных данных. В статье рассматривается процесс создания и обучения искусственной нейронной сети на модельных данных для решения задачи субоптимального управления. В качестве эталонных данных для обучения нейронной сети использовались режимы движения поезда, полученные методом Беллмана. Приведенные сравнительные результаты работы двух методов показывают применимость искусственных нейронных сетей для решения прикладных задач тяги поездов с возможностью непрерывного обучения, в том числе с использованием данных поездок, которые могут быть напрямую включены в обучающую или тестирующую выборку.

Ключевые слова: тяговые расчеты; оптимизация тяговых расчетов; нормирование расходов энергоресурсов на тягу поездов; искусственные нейронные сети; автоматические системы управления транспортными средствами; тяговые свойства локомотива; регулирование сил тяги и торможения

Введение. Железнодорожный транспорт является одним из основных потребителей электроэнергии и дизельного топлива в стране. Поэтому важной корпоративной задачей является снижение расхода топливно-энергетических ресурсов, в том числе на тягу поездов, позволяющее существенно сократить затраты компании. Затраты ОАО «РЖД» на электроэнергию по данным из годового отчета за 2018 г. составили 166,7 млрд руб., или 11 % от общих расходов, доля дизельного топлива составляет 8 % от общих рас-

ходов, или 110,7 млрд руб. Далее рассмотрим возможные пути снижения расхода электроэнергии на тягу поездов.

Решение задачи снижения расхода электроэнергии на тягу поездов может быть найдено при совершении сети передачи, устройств преобразования электроэнергии и путем оптимального или квазиоптимального управления движением поезда. Первое направление представляется достаточно затратным и длительным по времени, так как требует серьезных капитальных вложений на реконструкцию тягово-энергетической сети, обновление оборудования тягового подвижного состава. Второе направление не предполагает существенных капитальных затрат и может быть реализовано двумя способами. Первый заключается в разработке бортовых систем автоматического ресурсосберегающего управления. Недостатками такого подхода являются: низкая производительность для реализации детального расчета; необходимость определенных капитальных затрат на внедрение таких систем, которое к тому же растянуто во времени; необходимость проведения обслуживания и актуализации данных бортовых систем (электронная карта, характеристики подвижного состава и т. д.). Второй способ заключается в применении стационарных комплексов оперативного планирования расхода энергоресурсов на поездку. Преимуществами этого способа являются:

- отсутствие необходимости в капитальных вложениях по причине использования действующих в компании высокопроизводительных вычислительных комплексов;
- агрегирование данных о поездках;
- автоматическая актуализация информации о характеристиках и начальных условиях движения подвижного состава из записанных в поездке данных;
- получение более точных результатов априорного и апостериорного тягового расчета за счет более детализированной математической модели поезда.

Недостатком такого способа является меньшая оперативность в случае отсутствия постоянной связи с подвижным составом. Однако после массового внедрения

■ E-mail: needhelps@mail.ru (С. В. Малахов)

надежной беспроводной связи с инфраструктурой данный недостаток будет исправлен.

Как правило, реализация энергосберегающей стратегии ведения поезда или планирование энергозатрат на движение по участку заключается в нахождении экстремумов целевой функции, например с точки зрения энергозатрат в заданных условиях. Для электрической тяги рассматриваются первичные энергозатраты J , учитывающие коэффициент полезного действия (КПД) электровоза. Так, для постоянного тока

$$J = \int_0^T i(n(s, t), t) u(n(s, t), t) dt, \quad (1)$$

где i — ток электровоза, A ; u — напряжение на токоприемнике, B ; t — время, c ; T — заданное время хода, c ; s — координата поезда, m ; n — управление: позиция контроллера в тяге, выбег, ступень торможения.

Решение задачи оптимизации заключается в определении такой функции управления тягой, которая позволит минимизировать затраты энергии. Такое решение может быть найдено методами оптимального управления, которые обладают как достоинствами, так и некоторыми недостатками [1].

Наиболее предпочтительным с точки зрения отсутствия ограничений на подынтегральные функции (1) является метод динамического программирования [2, 3, 4, 5], заключающийся в дискретизации процесса движения и направленном переборе траекторий движения. Использование многоядерных процессоров и высокопроизводительных кластеров компьютеров позволяет создать многопоточную реализацию, которая достаточно эффективна для решения оптимальной задачи в стационарных условиях [5]. Для бортового применения динамического программирования без постоянной связи с инфраструктурой использование этого метода целесообразно для очень «грубой» модели поезда (без учета изменения напряжения на токоприемнике, расчета динамических сил внутри поезда, учета метеорологических факторов и других стохастических факторов и т. д.) с большими шагами варьирования управления и дискретизации по скорости. Фактически ранее задача оптимального управления рассматривалась только для точно заданных подынтегральных функций [1] и для выполнения адаптации без машинного обучения для применения в бортовой системе [6, 7], что не позволяло использовать весь объем накопленной рабочей информации в виде зарегистрированных на борту данных.

При эксплуатации системы управления следует учитывать то, что возможны ошибки из-за неточностей математической модели, начальной и рабочей информации. Неточность математической модели может быть снижена за счет дополнительной детализации. Неточности начальной информации могут

быть снижены за счет более качественной подготовки и проверки. Неточности рабочей информации снизить проблематично, так как они зависят от метрологических характеристик измерительных устройств, технического состояния систем поезда, случайных факторов с известными и неизвестными законами распределения вероятности. Поэтому требуется применять регулятор, основанный на адаптивном методе экстремального или квазиэкстремального управления.

Для решения проблемы неточности рабочей информации и реализации квазиоптимальных траекторий движения предлагается применять в дополнение к уже известным методам математический аппарат, использующий методологию машинного обучения. Далее будет рассмотрен один из методов машинного обучения, основанный на принципе идентификации объекта управления «вход-выход», т. е. искусственные нейронные сети (ИНС). Математиками А. Н. Колмогоровым и В. В. Арнольдом в 1957 г. была доказана теорема о представимости непрерывных функций нескольких переменных суперпозицией непрерывных функций одной переменной [8], которая в 1987 г. была переложена Хехт–Нильсеном для нейронных сетей: любая функция нескольких переменных может быть представлена двухслойной ИНС с прямыми полными связями с N нейронами входного слоя, $(2N+1)$ нейронами скрытого слоя с ограниченными функциями активации (например, сигмоидальными) и M нейронами выходного слоя с неизвестными функциями активации [9]. Из теоремы Колмогорова—Арнольда—Хехт–Нильсена (теорема КАХН) следует, что для любой функции многих переменных существует отображающая ее ИНС фиксированной размерности, при настройке (обучении) которой могут использоваться три степени свободы: область значений сигмоидальных функций активации нейронов скрытого слоя, наклон сигмоид нейронов этого слоя, вид функций активации нейронов выходного слоя [9]. Положения теоремы КАХН лежат в основе выбора регулятора ИНС для обозначенной задачи оптимизации.

ИНС представляют собой структуры простейших автоматов, которые имеют p входов и m выходов. Простейший автомат нейронной сети представляет собой нелинейный преобразователь и в общем случае выглядит следующим образом:

Входы—сумматор—активационная функция—выходы.

Выход связан с входами следующим соотношением:

$$OUT = F\left(\sum_{k=1}^N w_k x_k\right), \quad (2)$$

где F — активационная функция; w_k — вес входа нейрона; x_k — величина входа нейрона; N — количество входов нейрона.

Нейроны соединяются друг с другом и образуется ИНС, которая позволяет компактно хранить информацию, полученную при обучении, что, в свою очередь, позволяет применять несколько десятков или сотен обученных нейронных сетей для выбора лучшего решения в соответствии с (1). Наиболее применяемым алгоритмом обучения является метод обратного распространения [10]. Обучение ИНС является «дорогостоящим» этапом по сравнению с тестированием (валидацией) и эксплуатацией. Поэтому важно выбрать не только быстрый метод обучения, но и в целом успешную стратегию обучения. Выбор стратегии обучения ИНС не формализован и в общем случае является предметом поиска. Для рассматриваемого случая с целью ускорения получения ИНС, готовой для адаптации рабочей информации, на начальном этапе происходит обучение с «учителем», в качестве которого используется метод динамического программирования. Также обучение с «учителем» необходимо для того, чтобы обученная нейронная сеть для каждого текущего входа формировала выход, близкий к оптимальному, с точностью допустимой ошибки обучения (точность сходимости решения), заранее заложенной в алгоритм обучения.

Результаты расчета. На рис. 1 представлен график изменения суммарной среднеквадратической ошибки нейронной сети для одной эпохи обучения, т. е. после обучения сети на всем множестве пар «вход-выход» обучающей выборки. В данном случае обучающая выборка была составлена из 40 образцов и проводилось предварительное обучение на 100 эпохах для устранения эффекта необученной сети, который сопряжен с большими ошибками сети.

На рис. 2 представлен график изменения суммарной среднеквадратической ошибки нейронной сети для одной эпохи обучения после продолжения обучения ИНС на новой обучающей выборке. В данном случае обучающая выборка была из 165 образцов.

На рис. 3 показана зависимость ошибки при дообучении ИНС, т. е. при продолжении обучения на той же выборке при той же обучающей выборке, так как и во втором случае (рис. 2), когда был достигнут предел по эпохам обучения — 10 000. Предел по эпохам обучения подобран эмпирически с учетом времени обучения, которое зависит от размера сети, обучающей выборки и производительности компьютера. В большинстве случаев при правильном выборе размера сети и обучающей выборки обучение заканчивается успешно в пределах 10 000 эпох, но возможны и обратные случаи. Тогда требуется определить причины неудовлетворительного обучения и принять решение: дообучить, изменить структуру ИНС, изменить обучающую выборку.

Как видно из рис. 2, 3 график ошибки сети имеет всплески (попадания в локальные минимумы, пере-

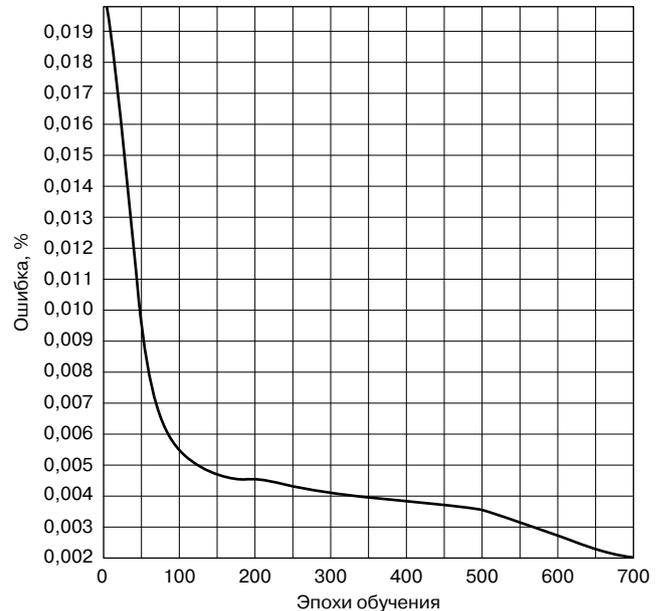


Рис. 1. График суммарной среднеквадратической ошибки при обучении ИНС на выборке из 40 образцов

Fig. 1. Graph of the total mean square error when training an artificial neural network (ANN) on a selection of 40 samples

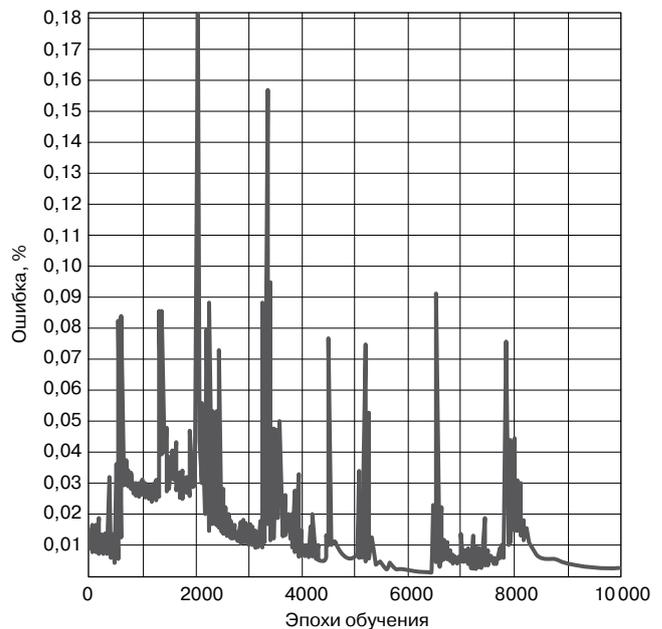


Рис. 2. График суммарной среднеквадратической ошибки при обучении ИНС, заранее обученной, на новой выборке из 165 образцов

Fig. 2. Graph of the total mean square error when training an ANN, pre-trained, on a new selection of 165 samples

обучения), что обусловлено алгоритмом обучения. Поэтому для повышения детерминированности процесса обучения и исключения данной ситуации важно применять известные методы [10]. Процесс

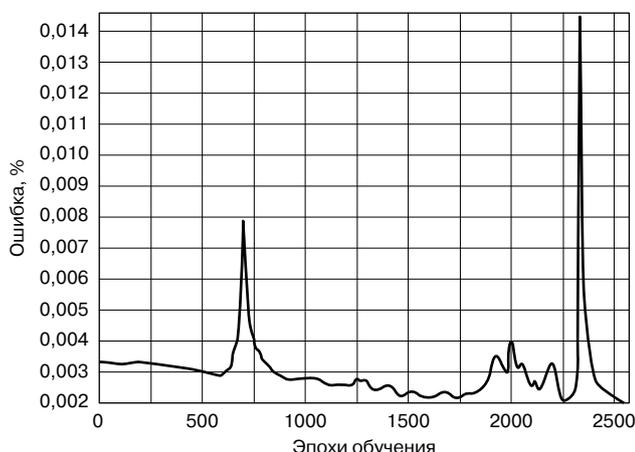


Рис. 3. График суммарной среднеквадратической ошибки ИНС при дообучении
 Fig. 3. Graph of the total mean square error of the ANN with additional training

обучения прекращается после достижения необходимого уровня ошибки в 0,001 % (рис. 3).

Обучение ИНС на всю поездку происходит для каждой смены режима движения поезда или чаще, если не была пройдена валидация сети. Для этого автоматически выбираются входы для конкретной смены режима движения поезда и проводится обучение

для всей поездки. В случае неудовлетворительного обучения выборка может быть изменена путем добавления новых образцов. Если в случае нескольких изменений обучающей выборки обучение не заканчивается успешно, то проводится анализ входных данных и реконструкция сети по известным алгоритмам [10]. Для рассматриваемой сети использовалась следующая начальная топология: один входной слой из восьми нейронов с сигмоидальной функцией активации, два скрытых слоя по 100 нейронов каждый с сигмоидальными функциями активации, два нейрона в выходном слое с линейной функцией активации.

На рис. 4 и 5 приведены кривые движения поезда, полученные в результате тягового расчета с применением метода динамического программирования и нейросетевого метода соответственно.

Для расчетной типовой поездки на тяговом плече 200 км происходит около 100–150 и более смен режимов движения поезда, учитывая только ходовые позиции, выбег, торможение. Поэтому объем входных данных невелик и обучение ИНС протекает достаточно быстро, не более минуты на образец (поездку) или 100–150 мин суммарно для 120 поездок с вариацией условий движения.

Обученная ИНС с использованием эталонов, полученных методом динамического программирования,

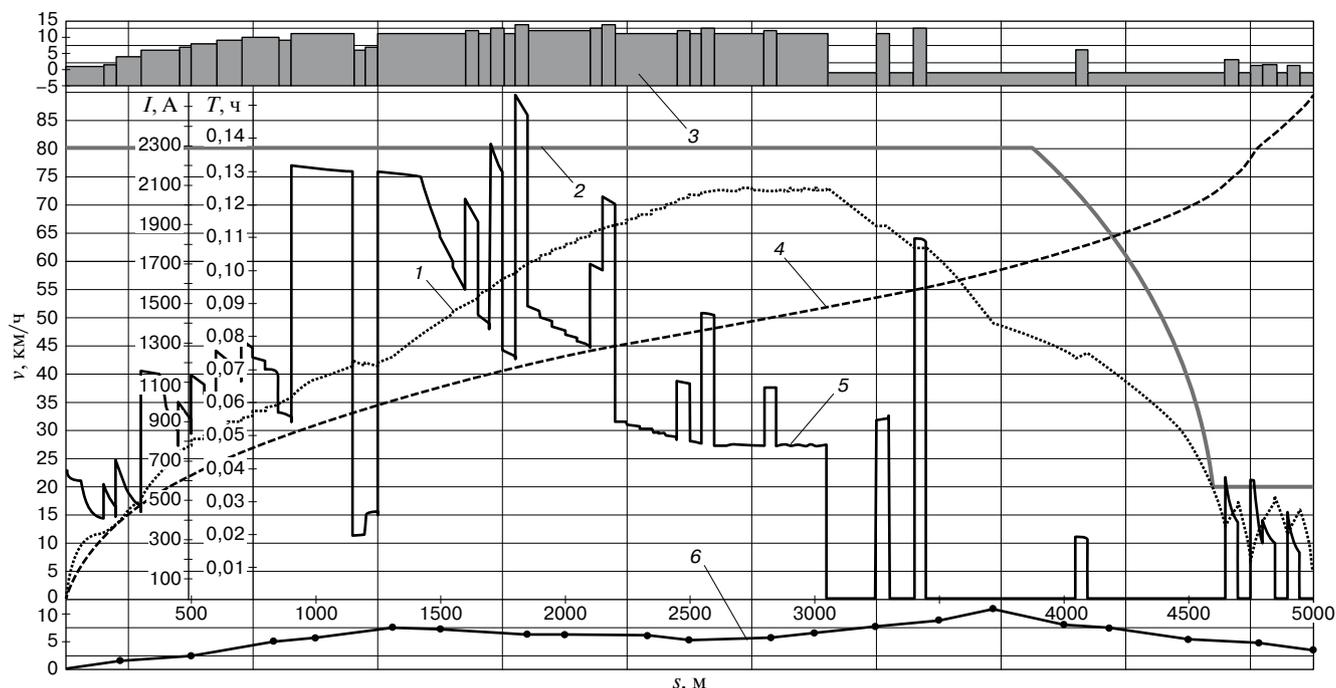


Рис. 4. Тяговый расчет методом динамического программирования с шагом дискретизации 50 м по координате и 1 км/ч по скорости:
 1 — скорость; 2 — допустимая скорость; 3 — режим движения; 4 — время; 5 — ток; 6 — профиль пути
 Fig. 4. Traction calculation by the dynamic programming method with a sampling step of 50 m in coordinate and 1 km/h in speed:
 1 — speed; 2 — permissible speed; 3 — driving mode; 4 — time; 5 — current; 6 — track profile

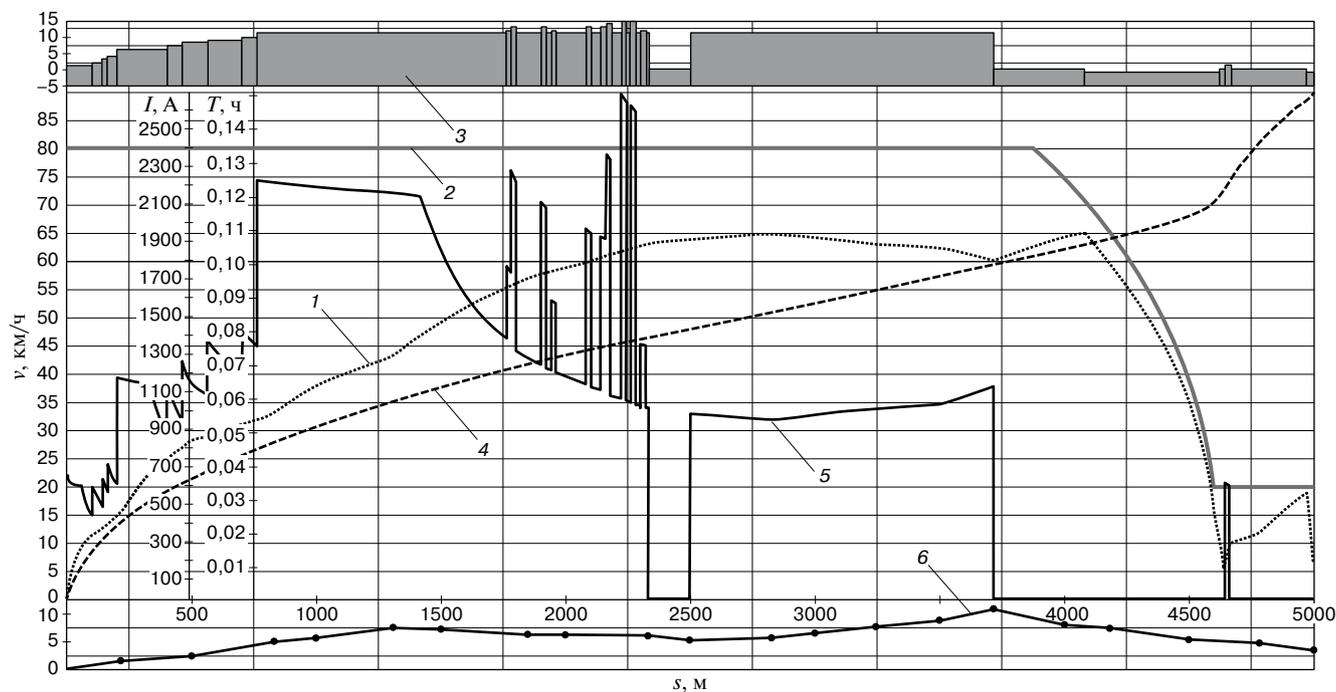


Рис. 5. Тяговый расчет нейросетевым методом после обучения на 120 поездках:
 1 — скорость; 2 — допустимая скорость; 3 — режим движения; 4 — время; 5 — ток; 6 — профиль пути
 Fig. 5. Traction calculation by the neural network method after training on 120 trips:
 1 — speed; 2 — permissible speed; 3 — driving mode; 4 — time; 5 — current; 6 — track profile

применяется с постоянным проведением дообучения с целью адаптации под конкретный тяговый подвижной состав или даже под конкретную тяговую единицу. Также могут быть созданы сети для более точного управления в условиях воздействия определенных факторов, так как обобщение сети без изменения ее размеров может увеличить погрешность управления. Положительным свойством обобщения является непрерывность сети в условиях, близких к расчетным, но не совпадающих с ними. Обобщение проверяется с помощью теста обученной ИНС на выборке, которая не была использована для обучения, и на выборке, полученной из данных, зарегистрированных в процессе движения поезда. Если ИНС проходит тест (суммарная ошибка на тестовой выборке меньше заданной), то обучение считается завершенным.

Однако во время движения может возникнуть ситуация, которая потребует кардинального пересмотра плана ведения поезда (например, дополнительные ограничения по скорости и прочее). В этом случае одной ИНС будет недостаточно и требуется использовать ИНС, которая обучалась по иному критерию. Для этого следует использовать аналогичный способ получения ИНС, но с учетом иного критерия оптимизации управления.

Выводы. 1. Применение ИНС в качестве квазиоптимального адаптивного регулятора позволит снизить

потребности в вычислительной мощности стационарного управляющего комплекса за счет обобщения и постоянной адаптации сети по сравнению с методами, не учитывающими погрешности в начальной и рабочей информации.

2. Индивидуальная адаптация позволит учитывать текущее состояние единицы тягового подвижного состава и фактически оценивать его энергоэффективность в процессе эксплуатации.

3. Низкие требования к вычислительным ресурсам при эксплуатации ИНС создают дополнительные преимущества по параллельному применению нескольких сотен или тысяч сетей — например, при неизвестной заранее массе поезда и заданном времени движения выбирается лучшая ИНС по критерию минимума энергозатрат.

СПИСОК ЛИТЕРАТУРЫ

1. Оптимизация управления движением поездов: учеб. пособие / Л. А. Баранов [и др.]; под ред. Л. А. Баранова. М.: МИИТ, 2011. 164 с.
2. Ерофеев Е. В. Выбор оптимального режима ведения поезда на АЦВМ с применением метода динамического программирования // Труды МИИТ. 1967. Вып. 228. С. 16–30.
3. Беллман Р., Дрейфус С. Прикладные задачи динамического программирования / пер. с англ. Н. М. Митрофановой; под ред. А. А. Первозванского. М.: Наука, 1965. 458 с.
4. Юренко К. И. Расчет энергооптимальных режимов движения перспективного подвижного состава методом динамического

программирования // Известия вузов. Электромеханика. 2013. № 3. С. 78–82.

5. Малахов С. В., Капустин М. Ю. Реализация динамического программирования с учетом эффективного пересчета в бортовой системе // Наука и техника транспорта. 2020. № 2. С. 74–80.

6. Мугинштейн Л. А., Илютович А. Е., Ябко И. А. Энергооптимальные методы управления движением поездов: сб. науч. тр. ОАО «ВНИИЖТ». М.: Интекст, 2012. 80 с.

7. Юренко К. И., Савоськин А. Н., Фандеев Е. И. Исследование оптимальных траекторий движения поезда с учетом случайных факторов // Труды 3-й науч.-техн. конф. «Интеллектуальные системы управления на железнодорожном транспорте ИСУЖТ-2014» (Москва, 18 ноября 2014 г.) / ОАО «НИИАС». М., 2014. С. 211–214.

8. Колмогоров А. Н. О представлении непрерывных функций нескольких переменных в виде суперпозиций непрерывных функций одного переменного и сложения // Доклады АН СССР. 1957. Т. 114. № 5. С. 953–956.

9. Hecht-Nielsen R. Kolmogorov's Mapping Neural Network Existence Theorem // IEEE First Annual Int. Conf. on Neural Networks. San Diego, 1987. Vol. 3. P. 11–13.

10. Хайкин С. Нейронные сети: полный курс. Изд. 2-е, испр. М.; СПб.: Диалектика, 2019. 1104 с.

ИНФОРМАЦИЯ ОБ АВТОРЕ

МАЛАХОВ Сергей Валерьевич, ассистент, кафедра «Тяговый подвижной состав», ФГАОУ ВО «РУТ» (МИИТ)

КАПУСТИН Михаил Юрьевич, канд. техн. наук, доцент, кафедра «Тяговый подвижной состав», ФГАОУ ВО «РУТ» (МИИТ); член Научно-технического совета ОАО «РЖД»

Статья поступила в редакцию 21.02.2020 г., актуализирована 28.10.2020 г., принята к публикации 30.11.2020 г.

Для цитирования: Малахов С. В., Капустин М. Ю. Метод построения адаптивного субоптимального стационарного регулятора движения поезда на основе искусственных нейронных сетей // Вестник Научно-исследовательского института железнодорожного транспорта (Вестник ВНИИЖТ). 2021. Т. 80. № 1. С. 13–19. DOI: <https://dx.doi.org/10.21780/2223-9731-2021-80-1-13-19>.

Method for constructing an adaptive suboptimal stationary train traffic controller based on artificial neural networks

S. V. MALAKHOV, M. Yu. KAPUSTIN

Federal State Autonomous Educational Institution of Higher Education "Russian University of Transport" (FGAOU VO "RUT" (MIIT)), Moscow, 127055, Russia

Abstract. The article discusses the modern methodology for performing the synthesis of a suboptimal train controller for the purpose of energy saving. The existing methods of optimal traction control have a number of disadvantages, the main one of which is the lack of direct use in the control program of the data obtained during train operation. Mathematical models used to solve the optimal problem can be used correctly only in the case of sufficient adequacy. Adequacy check is not part of the known methods of optimal control theory. To eliminate this drawback, it is proposed to use the method of optimal (suboptimal) traction calculations based on artificial neural networks. It improves the accuracy of traction calculations, which is especially important in the aspect of considering energy savings, while reducing the need for computing power. When using this method, it is possible not only to achieve results close to the classical Bellman method, but also to train or verify the network using the recorded data. The article discusses the process of creating and training an artificial neural network based on model data to solve the problem of suboptimal control. The train motion modes obtained by Bellman's method were used as reference data for training the neural network. The presented comparative results of the two methods show the applicability of artificial neural networks for solving applied problems of train traction with the possibility of continuous learning, including the use of trip data, which can be directly included in the training or testing set.

Keywords: traction calculations; optimization of traction calculations; rationing of energy consumption for train traction; artificial neural networks; automatic vehicle control systems; traction properties of the locomotive; regulation of traction and braking forces

DOI: <https://dx.doi.org/10.21780/2223-9731-2021-80-1-13-19>

REFERENCES

1. Baranov L. A., Erofeev E. V., Meleshin I. S., Chin' L. M. *Optimizatsiya upravleniya dvizheniem poezdov. Ucheb. posobie* [Optimization of train traffic control. Textbook]. Moscow, MIIT Publ., 2011, 164 p.
2. Erofeev E. V. *Vybor optimal'nogo rezhima vedeniya poezda na ATsVM s primeneniem metoda dinamicheskogo programmirovaniya* [The choice of the optimal mode of running a train on a digital computer using the method of dynamic programming]. Trudy MIIT [Proceedings of the MIIT], 1967, Vol. 228, pp. 16–30.
3. Bellman R., Dreyfus S. *Prikladnye zadachi dinamicheskogo programmirovaniya* [Applied problems of dynamic programming. English translation by N. M. Mitrofanova]. Moscow, Nauka Publ., 1965, 458 p.
4. Yurenko K. I. *Raschet energooptimal'nykh rezhimov dvizheniya perspektivnogo podvizhnogo sostava metodom dinamicheskogo programmirovaniya* [Calculation of energy-optimal modes of motion of perspective rolling stock by the method of dynamic programming]. Izvestiya vuzov. Elektromekhanika [University news. Electromechanics], 2013, no. 3, pp. 78–82.
5. Malakhov S. V., Kapustin M. Yu. *Realizatsiya dinamicheskogo programmirovaniya s uchetom effektivnogo perescheta v bortovoy sisteme* [Implementation of dynamic programming taking into account effective recalculation in the onboard system]. Science and Technology in Transport, 2020, no. 2, pp. 74–80.
6. Muginshhteyn L. A., Ilyutovich A. E., Yabko I. A. *Energooptimal'nye metody upravleniya dvizheniem poezdov. Sb. nauch. tr. OAO "VNIIZhT"* [Energy-optimal methods of train traffic control. Proc. of the JSC "VNIIZhT"]. Moscow, Intext Publ., 2012, 80 p.
7. Yurenko K. I., Savos'kin A. N., Fandeev E. I. *Issledovanie optimal'nykh traektoriy dvizheniya poezda s uchetom sluchaynykh faktorov* [Investigation of optimal trajectories of the train motion taking into account random factors]. Trudy 3-y nauch.-tekhn. konf.

“Интеллектуальные системы управления на железнодорожном транспорте ISUZHT-2014” (Москва, 18 ноября 2014 г.) [Proc. of the 3rd scientific and technical conference “Intelligent control systems in railway transport ISUZHT-2014” (Moscow, November 18, 2014)]. Moscow, JSC “NIIAS” Publ., 2014, pp. 211–214.

8. Kolmogorov A. N. *O predstavlenii nepreryvnykh funktsiy neskol'kikh peremennykh v vide superpozitsiy nepreryvnykh funktsiy odnogo peremennogo i slozheniya* [On the representation of continuous functions of several variables in the form of superpositions of continuous functions of one variable and addition]. Doklady AN SSSR [USSR Science Academy reports], 1957, Vol. 114, no. 5, pp. 953–956.

9. Hecht-Nielsen R. *Kolmogorov's Mapping Neural Network Existence Theorem*. IEEE First Annual Int. Conf. on Neural Networks. San Diego, 1987, Vol. 3, pp. 11–13.

10. Khaykin S. *Neyronnye seti: polnyy kurs* [Neural networks: Complete course]. Izd. 2-e, ispr. [Edition 2nd, revised]. Moscow, St. Petersburg, Dialektika Publ., 2019, 1104 p.

ABOUT THE AUTHORS

Sergey V. MALAKHOV,

Assistant, Department “Traction Rolling Stock”, FGAOU VO “RUT” (MIIT)

Mikhail Yu. KAPUSTIN,

Cand. Sci. (Eng.), Associate Professor, Department “Traction Rolling Stock”, FGAOU VO “RUT” (MIIT); member of the Scientific and Technical Council of the JSC “RZD”

Received 21.02.2020

Revised 28.10.2020

Accepted 30.11.2020

■ E-mail: needhelps@mail.ru (S. V. Malakhov)

For citation: Malakhov S. V., Kapustin M. Yu. Method for constructing an adaptive suboptimal stationary train traffic controller based on artificial neural networks // VNIIZHT Scientific Journal. 2021. 80 (1): 13–19 (In Russ.). DOI: <https://doi.org/10.21780/2223-9731-2021-80-1-13-19>.

ВНИМАНИЮ ЧИТАТЕЛЕЙ!

ДОПОЛНИТЕЛЬНОЕ ПРОФЕССИОНАЛЬНОЕ ОБРАЗОВАНИЕ В АО «ВНИИЖТ»

Центр дополнительного образования (ЦДО) (лиц. № 2329 от 11.08.2016 г.) проводит повышение квалификации и профессиональную переподготовку слушателей по следующим направлениям:

- Анализ, моделирование бизнес-архитектуры и бизнес-процессов, использование процессного подхода в управлении организацией (для руководителей и специалистов)
- Проектирование, изготовление и приемка сварных конструкций железнодорожного подвижного состава, управление качеством в сварке рельсов, проведение аудита сварочного производства
- Построение энергосберегающих графиков движения поездов с использованием автоматизированной системы АПК ЭЛЬБРУС
- Изучение технологии транспортных процессов
- Транспортная логистика
- Изучения принципов построения и функционирования автоматизированной системы контроля за работой специального подвижного состава
- Изучение устройств, диагностики и средств контроля состояния железнодорожного пути
- Эксплуатация, техническое обслуживание и ремонт подвижного состава и устройств электроснабжения

Программы обучения могут быть разработаны по инициативе заказчика с учетом профессиональной деятельности АО «ВНИИЖТ».

Обучение проводится как в очной форме, так и с применением дистанционных образовательных технологий.

По итогам освоения образовательных программ слушателям выдается документ о квалификации государственного образца.

Куратор ЦДО — Пархаев Алексей Александрович, кандидат социологических наук, заместитель Генерального директора по управлению персоналом и социальным вопросам.

По вопросам обучения обращаться по адресу: 129626, г. Москва, 3-я Мытищинская улица, д.10 Центр дополнительного образования. Тел.: +7 (495) 602-81-74, e-mail: shiryaeva.oksana@vniizht.ru

