

Транспортные системы Transport systems

Научная статья

Статья в открытом доступе

УДК 004.45

doi: 10.30987/2782-5957-2023-11-42-49

МЕТОДИКА ПРОГНОЗИРОВАНИЯ РЕСУРСА УЗЛОВ И ДЕТАЛЕЙ ЖЕЛЕЗНОДОРОЖНОГО ПОДВИЖНОГО СОСТАВА ПРИ ПОМОЩИ МАШИННОГО ОБУЧЕНИЯ

Константин Александрович Сергеев¹, Олег Игоревич Мироненко², Максим Владимирович Козлов^{3✉}, Никита Олегович Мироненко⁴

^{1,2,3} Российский университет транспорта, Москва, Россия

⁴ Московский государственный технический университет имени Н.Э. Баумана, Москва, Россия

¹ vagon-7@yandex.ru, <https://orcid.org/0009-0009-1792-9143>

² olemir@yandex.ru, <https://orcid.org/0009-0005-7596-655X>

³ kozlov_m.v@mail, <https://orcid.org/0000-0003-2987-568X>

⁴ 5646460@gmail.com, <https://orcid.org/0009-0001-3510-2838>

Аннотация

Цель исследования: Разработка системы прогнозирования срока эксплуатации узлов и деталей железнодорожного подвижного состава.

Задача, решению которой посвящена статья: Определение срока эксплуатации колес колесных пар железнодорожного подвижного состава до их очередной обточки.

Методы исследования представлена методика прогнозирования ресурса узлов и деталей железнодорожных колесных пар с использованием системы оценки ожидаемых параметров, включая пробег колес. Исследование включает использование трех различных алгоритмов машинного обучения: линейной регрессии, случайного леса и градиентного бустинга. Показаны обученные модели каждого алгоритма, а также сходимость метрик MSE, MAPE и R-squared при каждой итерации обучения.

Новизна работы результаты исследования

позволяют предсказывать период эксплуатации колесных пар с высокой точностью и включают механизм обратной связи для автоматизации и обновления модели, что повышает точность прогнозирования.

Результаты исследования: На основе представленной методики разработана система, позволяющая определять временной промежуток эксплуатации колес колесных пар подвижного состава до проведения очередной их обточки.

Выводы: Предлагаемая методика позволит прогнозировать период эксплуатации определенных узлов и деталей в условиях заданного полигона до момента восстановления их рабочего состояния, основываясь на системе оценки ожидаемых параметров при помощи машинного обучения.

Ключевые слова: разработки, процессы, производство, оптимизация, предприятие, колесная пара, искусственный интеллект, обучение.

Ссылка для цитирования:

Сергеев К.А. Методика прогнозирования ресурса узлов и деталей железнодорожного подвижного состава при помощи машинного обучения / К.А. Сергеев, О.И. Мироненко, М.В. Козлов, Н.О. Мироненко // Транспортное машиностроение. – 2023. - № 11. – С. 42-49. doi: 10.30987/2782-5957-2023-11-42-49.

Original article

Open Access Article

METHOD OF FORECASTING THE RESOURCE OF RAILWAY ROLLING STOCK COMPONENTS AND PARTS USING MACHINE LEARNING

Konstantin Aleksandrovich Sergeev¹, Oleg Igorevich Mironenko², Maksim Vladimirovich Kozlov^{3✉}, Nikita Olegovich Mironenko⁴

^{1,2,3} Russian University of Transport, Moscow, Russia

⁴ Bauman Moscow State Technical University, Moscow, Russia

¹ vagon-7@yandex.ru, <https://orcid.org/0009-0009-1792-9143>

² olemir@yandex.ru, <https://orcid.org/0009-0005-7596-655X>

³ kozlov_m.v@mail, <https://orcid.org/0000-0003-2987-568X>

⁴ 5646460@gmail.com, <https://orcid.org/0009-0001-3510-2838>

Abstract

The study objective is to develop a system for forecasting the service life of components and parts of railway rolling stock.

The task to which the paper is devoted is to determine the service life of wheel pairs of railway rolling stock before their next turning.

Research methods include a technique for forecasting the resource of components and parts of railway wheel pairs using a system for estimating expected parameters, including wheel run. The study includes the use of three different machine learning algorithms: linear regression, random forest and gradient boosting. The trained models of each algorithm are shown, as well as the convergence of MSE, MAPE and R-squared metrics at each iteration of learning.

The novelty of the work: the study results make it possible to predict the period of wheel pairs opera-

tion with high accuracy and include a feedback mechanism for automating and updating the model, which increases the accuracy of forecasting.

Research results: on the basis of the proposed method, a system is developed that allows determining the time interval of operation of rolling stock wheel pairs before their next turning.

Conclusions: the proposed method will make it possible to predict the period of operation of certain components and parts under the conditions of a given proving ground until their working condition is restored, based on a system for evaluating expected parameters using machine learning.

Keywords: developments, processes, production, optimization, enterprise, wheel pair, artificial intelligence, learning.

Reference for citing:

Sergeev KA, Mironenko OI, Kozlov MV, Mironenko NO. Method for forecasting the resource of railway rolling stock components and parts using machine learning. *Transport Engineering*. 2023; 11:42-49. doi: 10.30987/2782-5957-2023-11-42-49.

Введение

Износ узлов и деталей подвижного состава зависит от ряда факторов, определяющих условия их эксплуатации. При этом, если имеет место ограниченный полигон эксплуатации, характеризующийся в определенном приближении постоянными параметрами (профиль и техническое состояние пути, климатические условия, скорость движения и т.д.), то, имея статистику по результатам обследования их технического состояния в течение определенного промежутка времени и периодически дополняя ее новыми наблюдениями, можно разработать систему, определяющую период эксплуатации определенных узлов и деталей в условиях данного полигона до момента восстановления их рабо-

чего состояния, основываясь на оценке ожидаемых параметров (пробега колес колесных пар, для последующей ее обточки).

В данной работе изложена методика прогнозирования ресурса узлов и деталей железнодорожного состава на примере разработки системы с использованием методов машинного обучения для решения задач регрессии, определяющей время очередной обточки колес колесных пар железнодорожного подвижного состава на основе имеющейся статистики по износу профиля катания колес. Исходные данные для системы поставляются с прибора бесконтактного измерения параметров колесных пар подвижного состава *Calipri-Ferberg CW-40* [1-3].

Материалы, модели, эксперименты и методы

Общая схема разрабатываемой системы представлена на рис. 1, где:

• **Загрузка данных:** параметры колес колесных пар (состояние профиля катания колес), которые поступают с прибора *Calipri-Ferberg*, в формате CSV.

• **Проверка и обработка данных:** предварительная обработка данных, включающая в себя следующие этапы:

1. Проверка на выбросы. В данных могут присутствовать ошибочные или аномальные значения, которые искажают ре-

зультаты анализа. Необходимо идентифицировать и удалить выбросы или применить методы замены аномальных значений на корректные.

2. Проверка и устранение пропущенных значений.

3. Создание новых признаков для машинного обучения, на основе существующих данных, улучшающих точность модели. Вычислить процент износа колеса, объединить несколько параметров в один, добавить дополнительные временные характеристики и т.д.

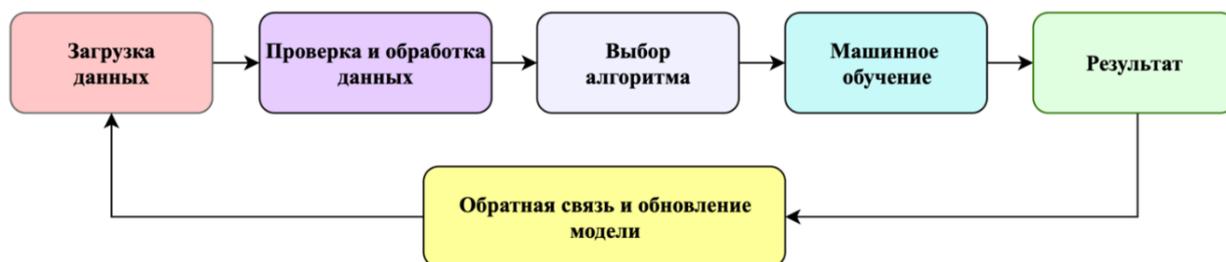


Рис. 1. Общая функциональная схема системы
Fig. 1. General functional scheme of the system

Выбор алгоритма. Выбор модели машинного обучения является одним из важных этапов, включающим в себя поиск алгоритмов и библиотек, удовлетворяющих требованиям решения задачи предсказания износа и времени очередной обточки колесных пар на основе его параметров. Из множества алгоритмов отбирается несколько подходящих, затем они проходят обучение на тестовых данных, и, лучшая модель используется для предсказания [4]. В данной системе используются следующие алгоритмы.

Линейная регрессия. На первом этапе для оценки правильности предобработки данных будет использоваться линейная

регрессия, которая предназначена для моделирования и анализа отношения между целевой переменной (пробег колес колесных пар до последующей обточки) и признаками (параметры, на которых обучается модель), которые должны быть независимыми.

Линейная регрессия стремится выявить линейную связь между признаками и целевой переменной, используя метод минимизации квадратичных отклонений. Это позволяет определить коэффициенты и константу линейной модели.

Модель линейной регрессии может быть выражена уравнением вида

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon,$$

где Y – целевая переменная; X_1, X_2, \dots, X_k – независимые переменные; $\beta_0, \beta_1, \beta_2, \dots, \beta_k$ – коэффициенты регрессии; ε – ошибка между фактическими и предсказанными значениями.

На рис. 2 показана обученная модель линейной регрессии на массиве данных пробега колеса колесной пары и процента износа.

Случайный лес. Случайный лес – является ансамблем решающих деревьев. Каждое дерево обучается на случайной выборке данных и случайном подмножестве признаков. Модель комбинирует

предсказания всех деревьев для получения итогового предсказания и позволяет исследовать сложные взаимосвязи между параметрами колеса колесной пары и его эксплуатационными характеристиками.

Последовательность обучения случайного леса:

1. **Выбор случайной подвыборки данных.** Исходные данные разбиваются на случайные подмножества, которые могут перекрываться. Это позволяет каждому дереву в лесу учиться на разных данных и увеличивает репрезентативность модели.

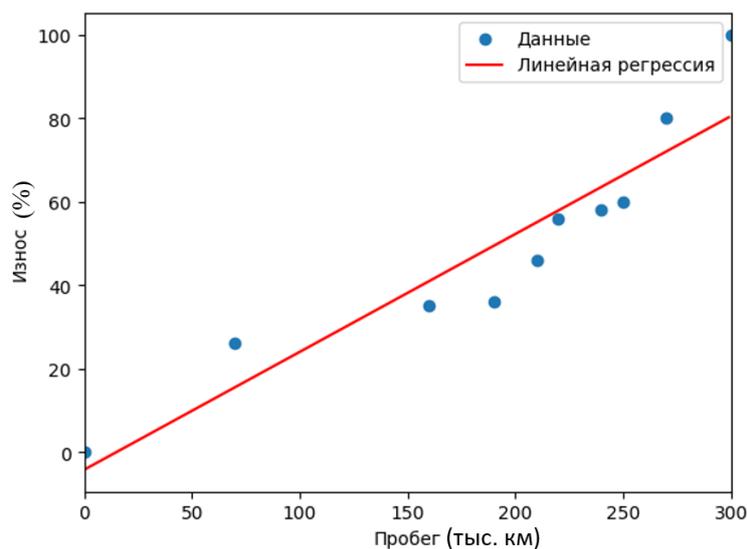


Рис. 2. Обученная модель линейной регрессии
 Fig. 2. Trained linear regression model

2. Выбор случайного подмножества признаков. При построении каждого дерева, из полного набора признаков случайным образом выбирается только некоторое подмножество признаков. Это способствует уменьшению корреляции между деревьями в ансамбле.

3. Построение деревьев решений. Для каждой выборки данных и подмножества признаков строится отдельное дерево решений. Каждое дерево разделяет данные на основе различных признаков и их значений.

4. Комбинирование результатов. После построения всех деревьев, их прогнозы комбинируются для получения

окончательного прогноза модели случайного леса.

5. Оценка важности признаков. Случайный лес предоставляет информацию о важности каждого признака в модели, что помогает в анализе данных и определении наиболее значимых факторов.

Данная последовательность обучения случайного леса позволяет получать устойчивые и точные прогнозы, а также обнаруживает сложные взаимосвязи в данных. На рис. 3 показана обученная модель случайного леса на массиве данных пробега колеса колесной пары и процента износа.

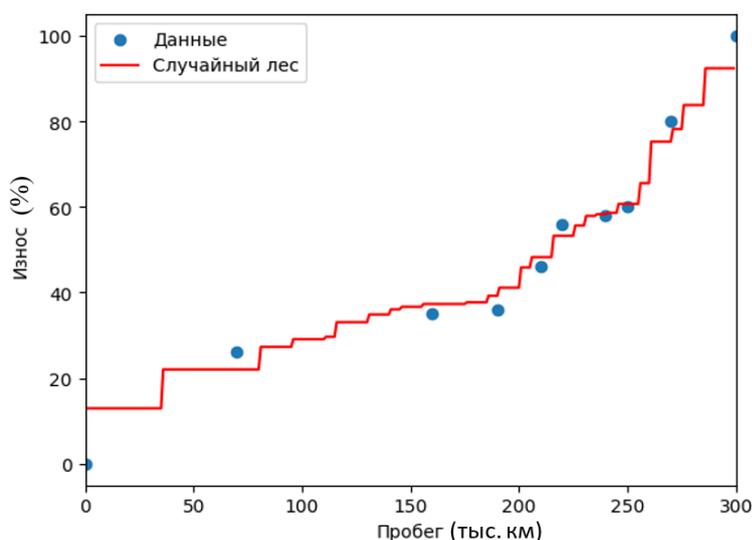


Рис. 3. Обученная модель случайного леса
 Fig. 3. Trained Random Forest model

Градиентный бустинг. Градиентный бустинг – ансамблевый метод, который комбинирует множество слабых моделей. Модель обучается последовательно, каждая следующая модель исправляет ошибки предыдущей (градиент ошибки). Градиент ошибки представляет собой вектор, который указывает направление наибольшего увеличения функции потерь модели. В процессе обучения каждая последующая модель в ансамбле строится

таким образом, чтобы минимизировать этот градиент ошибки, тем самым уменьшая общую ошибку предсказания. Этот итеративный подход позволяет градиентному бустингу последовательно улучшать предсказательную способность модели и приближаться к наилучшей точности предсказания. На рис. 4 показана обученная модель градиентного бустинга на массиве данных пробега колеса колесной пары и процента износа.

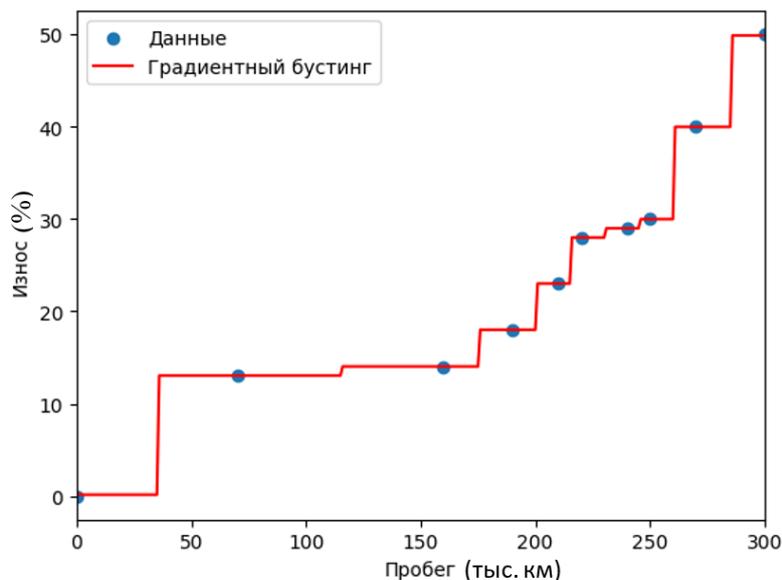


Рис. 4. Обученная модель градиентного бустинга
 Fig. 4. Trained gradient boosting model

• **Машинное обучение:** после выбора алгоритмов машинного обучения, модели обучаются на предварительно обработанных данных. Данные разделяются на обучающую и тестовую выборки. Обучающая выборка используется для обучения модели, а тестовая выборка – для оценки ее производительности и проверки способности корректно предсказывать значения на новых данных.

Процесс обучения модели включает в себя поиск гиперпараметров на тренировочных данных при помощи оптимизации функции потерь [5]. Для регрессионных моделей используются различные метрики оценки. Для данной системы выбраны сле-

дующие метрики: среднеквадратическая ошибка MSE (Mean Squared Error), $MAPE$ (Mean Absolute Percentage Error) и коэффициент детерминации (R -squared).

Задача регрессии состоит в следующем: по обучающей выборке строится модель $f(x)$.

$$(x_i, y_i)_{i=1}^N,$$

где x_i – набор признаков; y_i – набор целевых переменных; N – фиксированное количество признаков и целевых переменных.

Среднеквадратическая ошибка рассчитывается по следующей формуле:

$$MSE(y^{true}, y^{pred}) = \frac{1}{N} \sum_{i=1}^N (y_i - f(x_i))^2$$

где y^{true} – правильные ответы; y^{pred} – предсказанные алгоритмом ответы. Показание

сходимости метрики MSE при каждой итерации обучения модели показана на рис. 5.

Метрика MSE делает более заметными различия в предсказаниях, когда они сильно отличаются друг от друга, но она менее удобна, так как измеряет расхождение в квадратных единицах.

Для оценки точности отклонение прогнозов от фактических значений в про-

центном отношении, используем метрику $MAPE$.

$$MAPE(y^{true}, y^{pred}) = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - f(x_i)|}{|y_i|}$$

где y^{true} – правильные ответы; y^{pred} – предсказанные алгоритмом ответы.

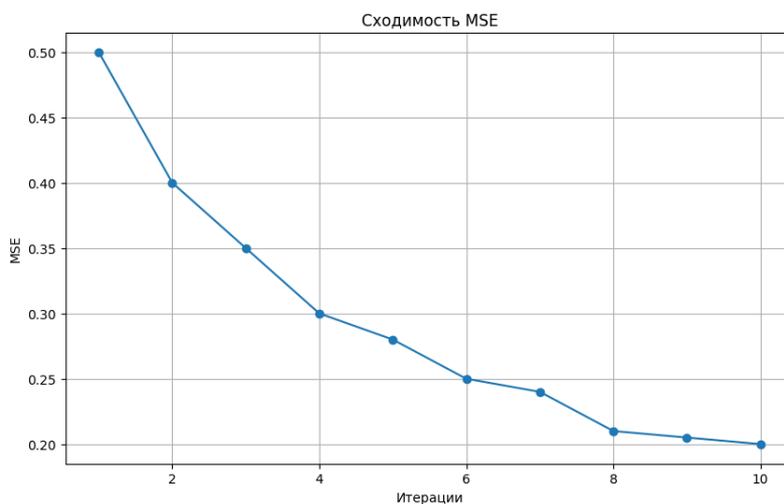


Рис. 5. Сходимость метрики MSE
 Fig. 5. Convergence of the metric MSE

$MAPE$ измеряется в процентах, что делает его результаты более понятными. Это позволяет легче интерпретировать точность прогнозов и делать выводы о том, насколько сильно прогнозы отклоняются от фактических данных. Она позволяет сравнивать точность прогнозов в разных доменах, независимо от масштаба данных. Расчет довольно прост, и его можно быстро применить к большим объ-

емам данных. Это делает ее удобным инструментом для быстрого оценивания точности прогнозов. Нужно заметить, что $MAPE$ имеет ограничения, чувствительность к нулевым значениям, проблемы с делением на ноль при нулевых фактических значениях и т.д. Показание сходимости метрики $MAPE$ при каждой итерации обучения модели показана на рис. 6.

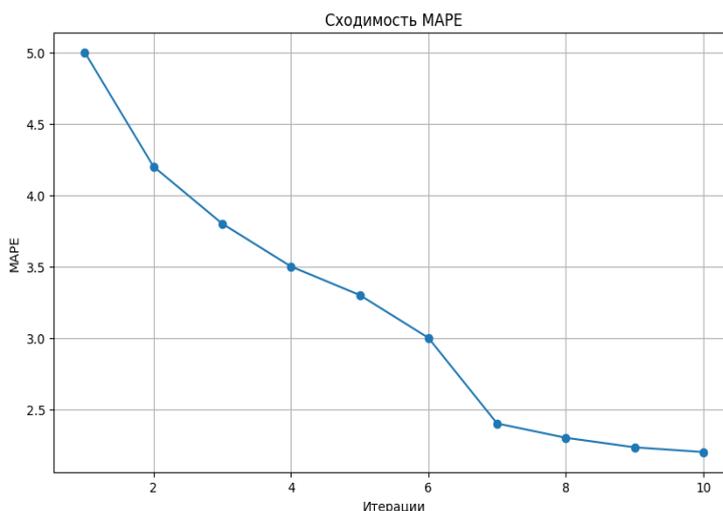


Рис. 6. Сходимость метрики $MAPE$
 Fig. 6. Convergence of the metric $MAPE$

Для измерения того, насколько модель линейной регрессии соответствует данным, на которых она основана, используется коэффициент детерминации (*R-squared*), представляющий собой статистический показатель, показывающий,

насколько хорошо эта модель объясняет неустойчивость зависимой переменной. Показание сходимости метрики *R-squared* при каждой итерации обучении модели показана на рис. 7.

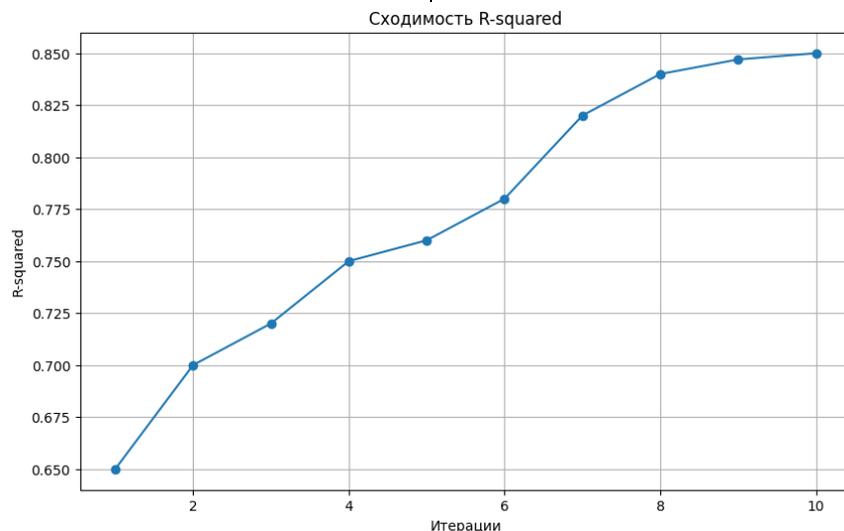


Рис. 7. Сходимость метрики *R-squared*
 Fig. 7. Convergence of the metric *R-squared*

•**Результат:** в результате работы системы будет выдана оценка ожидаемого пробега колес колесных пар на основе обработанных данных.

•**Обратная связь и обновление модели:** обратная связь и обновление модели

(конвейер) предназначен для автоматизации и отсутствию ручного повтора для вышеперечисленных действий, что позволяет увеличить скорость обработки и обеспечит более точный результат.

Результаты

Представленная методика позволит прогнозировать период эксплуатации определенных узлов и деталей в условиях данного полигона до момента восстановления их рабочего состояния, основываясь на системе оценки ожидаемых параметров (пробега колес колесных пар, для после-

дующей ее обточке) при помощи машинного обучения. При этом предусмотренный в системе механизм обратной связи, который добавляет новые данные, используя их для обновления модели машинного обучения, увеличивая точность оценки прогнозирования.

СПИСОК ИСТОЧНИКОВ

1. Плас Д.В. Python для сложных задач. Наука о данных и машинное обучение. Руководство / Д.В. Плас. М.: Питер, 2018. 759 с.
2. Beysolow T. II. Applied Reinforcement Learning with Python / T. Beysolow II. With OpenAI Gym, Tensorflow and Keras. Apress. 2019. ISBN 978-1-4842-5127-0.
3. Колесникова Г.И. Искусственный интеллект: проблемы и перспективы / Г.И. Колесникова // Видеонаука: сетевой журн. 2018. No 2(10). URL <https://videonauka.ru/stati/44-novye-tehnologii/190-iskusstvennyj-intellekt-problemy-i-perspektivy>.
4. Солнцева О.Г. Аспекты применения технологий искусственного интеллекта / О.Г. Солнцева // E-Management. 2018. No1. URL: <https://cyberleninka.ru/article/n/aspekty-primeneniya-tehnologiy-iskusstvennogo-intellekta>.
5. Шарден Б. Крупномасштабное машинное обучение вместе с Python : учебное пособие / Б. Шарден, Л. Массарон, А. Боскетти ; перевод с английского А. В. Логунова. Москва : ДМК Пресс, 2018. 358с. ISBN 978-5-97060-506-6. Текст : электронный // Лань : электронно-библиотечная система. URL: <https://e.lanbook.com/book/105836>.

REFERENCES

1. Plas JV. Python data science handbook. Moscow: Piter. 2018.
2. Beysolow T. II. Applied reinforcement learning with Python: with OpenAI gym, tensorflow, and keras. Apress. 2019.
3. Kolesnikova GI. Artificial intelligence: problems and prospects. Videohauka [Internet]. 2018;2(10). Available from: <https://videonauka.ru/stati/44-novye-tehnologii/190-iskusstvennyj-intellekt-problemy-i-perspektivy>.
4. Solntseva OG. Aspects of applying artificial intelligence technologies. E-Management [Internet]. 2018;1. Available from: <https://cyberleninka.ru/article/n/aspecty-primeneniya-tehnologiy-iskusstvennogo-intellekta>.
5. Sharden B, Massaron L, Bosketti A. Large-scale machine learning with Python: textbook. Moscow: DMK Press; 2018.

Информация об авторах:

Сергеев Константин Александрович - доктор технических наук, профессор кафедры «Нетяговый подвижной состав» Российского университета транспорта (РУТ (МИИТ)), e-mail: vagon-7@yandex.ru.

Мироненко Олег Игоревич – кандидат технических наук, доцент кафедры «Нетяговый подвижной состав» Российского университета транспорта (РУТ (МИИТ)), e-mail: olemir@yandex.ru.

Sergeev Konstantin Aleksandrovich - Doctor of Technical Sciences, Professor of the Department of Non-traction Rolling Stock of Russian Universal Transport (RUT (MIIT)), e-mail: vagon-7@yandex.ru.

Mironenko Oleg Igorevich – Candidate of Technical Sciences, Associate Professor of the Department of Non-traction Rolling Stock of Russian University of Transport (RUT (MIIT)), e-mail: olemir@yandex.ru.

Козлов Максим Владимирович – кандидат технических наук, доцент кафедры «Нетяговый подвижной состав» Российского университета транспорта (РУТ (МИИТ)), e-mail: [kozlov_m.v@mail](mailto:kozlov_m.v@mail.ru).

Мироненко Никита Олегович – студент Московского государственного технического университета имени Н.Э. Баумана (МГТУ), e-mail: 5646460@gmail.com.

Kozlov Maksim Vladimirovich – Candidate of Technical Sciences, Associate Professor of the Department of Non-traction Rolling Stock of Russian University of Transport (RUT (MIIT)), e-mail: ko-zlov_m.v@mail.

Mironenko Nikita Olegovich – Student of Bauman Moscow State Technical University (MSTU), e-mail: 5646460@gmail.com.

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации.
Contribution of the authors: the authors contributed equally to this article.

Авторы заявляют об отсутствии конфликта интересов.
The authors declare no conflicts of interests.

Статья опубликована в режиме Open Access.
Article published in Open Access mode.

Статья поступила в редакцию 11.09.2023; одобрена после рецензирования 24.10.2023; принята к публикации 27.10.2023. Рецензент – Антипин Д.Я., кандидат технических наук, доцент кафедры «Подвижной состав железных дорог», директор учебно-научного института транспорта Брянского государственного технического университета, член редсовета журнала «Транспортное машиностроение».

The article was submitted to the editorial office on 11.09.2023; approved after review on 24.10.2023; accepted for publication on 27.10.2023. The reviewer is Antipin D.Ya., Candidate of Technical Sciences, Associate Professor of the Department of Railway Rolling Stock, Director of the Educational and Scientific Institute of Transport at Bryansk State Technical University, member of the Editorial Board of the journal *Transport Engineering*.