

Научная статья
Статья в открытом доступе
УДК 621.892
doi: 10.30987/2782-5957-2025-1-62-67

ИСПОЛЬЗОВАНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ ПЛАНИРОВАНИЯ ПОСТАВОК МОТОРНЫХ МАСЕЛ

Эдуард Васильевич Лаушкин^{1✉}, Валерий Юрьевич Чернов², Валерий Алексеевич Пашинин³

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

¹ Eduard_evgen@bk.ru

² Valerkov2010@yandex.ru

³ Pashininmiit@yandex.ru

Аннотация

Рассматривается процесс применения машинного обучения для расчета поставок моторных масел на полигоны железных дорог. Целью исследования является применение искусственного интеллекта и других способов машинного обучения по обеспечению поставок моторных масел, для обеспечения стабильной эксплуатационной работы тягового подвижного состава. Проанализирована возможность применения машинного обучения для повышения точность планирования поставок моторных масел на полигоны железных дорог, исключив из расчета человеческий фактор. В качестве

методов исследования приняты: метод использования тепловой карты, методы машинного обучения, разведывательный анализ, линейная регрессия. В результате исследования установлено, что при разработке программы для расчета поставок моторных масел на использования на тяговом подвижном составе целесообразнее использовать модель регрессии Лассо.

Ключевые слова: обучение, моторные масла, железнодорожный транспорт, инновации, смазочные материалы, тепловозы, искусственный интеллект.

Ссылка для цитирования:

Лаушкин Э.В. Использование машинного обучения для повышения точности планирования поставок моторных масел / Э.В. Лаушкин, В.Ю. Чернов, В.А. Пашинин // Транспортное машиностроение. – 2025. - № 1. – С. 62-67. doi: 10.30987/2782-5957-2025-1-62-67.

Original article
Open Access Article

USE OF MACHINE LEARNING TO IMPROVE THE ACCURACY OF PLANNING ENGINE OIL SUPPLY

Eduard Vasilyevich Laushkin^{1✉}, Valery Yuryevich Chernov², Valery Alekseevich Pashinin³

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

¹ Eduard_evgen@bk.ru

² Valerkov2010@yandex.ru

³ Pashininmiit@yandex.ru

Abstract

Application of machine learning to calculate the supply of motor oils to railway grounds is considered. The study objective is to use artificial intelligence and other machine learning methods to ensure the supply of motor oils and to provide stable operation of traction rolling stock. The possibility of using machine learning to improve the accuracy of planning the supply of motor oils to railway grounds, excluding the human factor from the calculation, is analyzed. The following re-

search methods are used: the method of using a heat map, machine learning methods, intelligence analysis, and linear regression. As a result of the study, it is found that it is more expedient to use Lasso Regression when developing a program for calculating the supply of motor oils for its use in traction rolling stock.

Keywords: training, motor oils, railway transport, innovations, lubricants, diesel locomotives, artificial intelligence.

Reference for citing:

Laushkin EV, Chernov VYu, Pashinin VA. Use of machine learning to improve the accuracy of planning engine oil supply. *Transport Engineering*. 2025;1: 62-67. doi: 10.30987/2782-5957-2025-1-62-67.

Введение

С целью повышения энергетической эффективности в компании утверждена распоряжением ОАО «РЖД» от 15 декабря 2011 № 2718р «Энергетическая стратегия холдинга на период до 2015 года и на перспективу до 2030 года» [1]. Приоритетными направлениями определенной данной Стратегией является полное и надежное энергетическое обеспечение перевозочного процесса, снижение рисков при кризисных ситуациях в энергообеспечении железнодорожного транспорта, а также повышение показателей энергетической эффективности.

Одним из инструментов позволяющих обеспечить выполнение указанных целей Энергетической стратегией является улучшение организации систем учета и повышение точности планирования расходов, в том числе моторных масел на тяговом подвижном составе.

Следует отметить, что для расчета расхода моторного масла на эксплуатацию («на угар») тягового подвижного состава – тепловозов, автомотрис и рельсовых автобусов (далее – ТПС), в зависимости от условий его эксплуатации и марки масла утверждена Методика расчета расхода моторного масла на

эксплуатацию тягового подвижного состава от 11 апреля 2012 № 717р (в редакции распоряжения ОАО «РЖД» от 29 октября 2021 г. № 2349/р) [2].

В соответствии с данной методикой расчет моторного масла на эксплуатацию («угар») производится, согласно значениям коэффициентов, с учетом данных о пробегах локомотивов от последних видов ремонта КР и ТР-3 (ТР-2). При этом процесс производства данного посекционного расчета расходов моторных масел на эксплуатацию является энергоемким и требует значительного времени работников для его формирования. Кроме того, отсутствие автоматического расчета расходов и человеческий фактор в значительной степени влияют на качество и точность произведенных расходов, что может привести к негативным последствиям.

Одним из инструментов по повышению точности планирования расходов с учетом большого количества факторов является исключение человеческого фактора из планирования расходов, а также использование в расчетах алгоритмов искусственного интеллекта и других способов машинного обучения [3-6].

Материалы и методы

После глубокого изучения вопроса и определения актуальности проблемы принято решение создания прототипа программы и анализ целесообразности разработки программы с дальнейшей её интеграцией в систему интеллектуального управления парком локомотивов. Для этого были собраны данные эксплуатации и выполнены следующие действия:

- предварительный анализ на основе бухгалтерских данных о перемещении моторных масел;
- составлена тепловая карта для выявления скрытых взаимосвязей и тенденций;
- определен список методов машинного обучения для прогнозирования расхода масла «на угар»;

– выполнено несколько итераций обучения моделей из списка с применением метода кросс-валидации;

– выполнено сравнение полученных результатов, сформулирован вывод.

На основании полученных результатов был сделан вывод о том, что применение программы специалистами дирекции тяги на полигонах железных дорог обеспечит оптимизацию расходов и целевое использование денежных средств, а также позволит устранить возникновение рисков срыва эксплуатационной работы из-за отсутствия смазочных материалов на топливных складах.

Поскольку для решения задачи будем применять методы машинного обучения, то важно на начальном этапе исследований качественно провести разведывательный анализ. Разведы-

вательный анализ играет важную роль при работе с большими объемами исходных данных и большим количеством параметров, особенно в контексте решения такой задачи, как определение расхода моторного масла на угар в зависимости от расхода топлива у локомотивов.

Для валидации корреляций между данными важно понимать структуру исходных данных, физические процессы, а также технологию эксплуатации тягового подвижного состава в различных видах движения.

На данном этапе выполнено:

- определение однородных параметров;

Результаты

После завершения разведывательного анализа осуществлен переход к обучению моделей машинного обучения. На этапе выполняется создание алгоритмов, которые способны извлекать закономерности из данных и использовать их для принятия решений или прогнозирования будущих событий. Перед началом обучения моделей выполнено разделение исходной выборки на тренировочную, тестовую и валидационную. После выбора, подходящего списка алгоритмов машинного обучения осуществлен переход к настройке гиперпараметров. По результатам обучения моделей и последующей их оценке выполнена оптимизация с помощью кросс-валидации.

Для демонстрации результатов исследования приведены результаты обучения моделей.

Для определения лучшего способа решения данной задачи использовались методы:

- *RandomForestRegressor* (метод случайного леса);
- *LinearRegression* (линейная регрессия);
- *Ridge* (гребневая регрессия);
- *Lasso* (метод регрессии Лассо);
- *SVR* (метод опорных векторов);
- *KNeighborsRegressor* (метод ближайших соседей);
- *DecisionTreeRegressor* (дерево принятия решений).

После запуска функции обучения и сравнения моделей с использованием пара-

- разделение параметров на категориальные и численные;

- разделение параметров на входные и выходные.

В результате проведения разведывательного анализа установили категориальные и численные признаки.

К категориальным отнесли следующие признаки: принадлежность тепловоза к дороге, депо приписки, марка горючесмазочного материала, серия, номер, секция.

К численным отнесли расход дизельного топлива.

метров по умолчанию получили результаты, представленные в таблице 1.

Из табл. 1 видно, что лучшие результаты показывает модель *Ridge*. Данная модель демонстрирует наилучшие свойства (R^2), точность ($RMSE$, MAE) и минимальные отклонения между реальными и предсказанными значениями (max_error).

Для улучшения производительности моделей, выполнена настройка гиперпараметров модели с помощью метода переменной проверки и оценим результаты обучения, представленные в табл. 2.

Из табл. 2 видно, что модель *Lasso* показала лучшие результаты. Хорошие результаты также продемонстрировали модели *Ridge* и *SVR*.

Очевидно, что, после подбора гиперпараметров, характеристики обучаемых моделей значительно улучшились.

После выбора лучшего способа для описания исходных данных произведено предсказание данных «выходных» и построен график, которым они соответствуют [7].

График, расположенный на рисунке показывает, что все точки данных располагаются вдоль линии регрессии без отклонений, выбросов и ошибок. Линия регрессии Лассо лучшая модель, которая полностью соответствует линиям исходных данных [8].

Таблица 1

Значения метрик оценки качества моделей с параметрами по умолчанию

Table 1

Values of metrics for evaluating the quality of models with default parameters

	R2	RMSE	MAE	MAPE	max_error
DummyRegressor (strategy='mean', constant=None, quantile=None)	-0.017600	-1.435112	-0.965843	-1267472716286217.500000	-6.602947
LinearRegression (fit_intercept=True, copy_X=True, n_jobs=None, positive=False)	0.999615	-0.023993	-0.011398	-14690039828794.697266	-0.107085
Ridge (alpha=1.0, positive=False, solver='auto')	0.999961	-0.008536	-0.005824	-7813173743747.091797	-0.033919
Lasso (alpha=1.0)	0.523507	-0.992448	-0.662008	-864133394329000.750000	-4.625197
SVR (C=1.0, kernel='rbf')	0.980673	-0.195296	-0.097607	-125354911212013.656250	-1.142975
KNeighborsRegressor (n_neighbors=5)	0.801829	-0.617387	-0.374053	-397344406759940.125000	-2.845400
DecisionTreeRegressor (criterion='squared_error', max_depth=None, max_features=None, random_state=None)	0.974503	-0.203951	-0.038531	-0.011200	-1.484000
RandomForestRegressor (bootstrap=False, criterion='absolute_error', max_depth=5, max_features=11, random_state=3128)	0.983702	-0.140466	-0.025002	-0.007762	-1.023640

Таблица 2

Значения метрик оценки качества моделей с наилучшими параметрами

Table 2

Values of metrics for evaluating the quality of models with the best parameters

	R2	RMSE	MAE	MAPE	max_error
Ridge (alpha=10, positive=True, solver='lbfgs')	0.999413	-0.034488	-0.022632	-31432276885005.113281	-0.158163
Lasso (alpha=0.001)	1.000000	-0.000992	-0.000662	-864133394328.797363	-0.004625
SVR (C=0.03, kernel='linear')	0.996911	-0.076896	-0.065295	-99342182707783.968750	-0.239227
KNeighborsRegressor (n_neighbors=3)	0.828234	-0.572572	-0.343205	-321733453119914.687500	-2.596667
DecisionTreeRegressor (criterion='absolute_error', max_depth=3, max_features=9, random_state=3128)	0.593247	-0.921784	-0.573212	-651080134181336.375000	-5.011000
RandomForestRegressor (bootstrap=False, criterion='absolute_error', max_depth=5, max_features=11, random_state=3128)	0.064310	-1.375907	-0.841869	-851427464602576.000000	-6.567710

Заключение

Проведенные исследования показывают, что применение машинного обучения в решении задач по расчету поставок моторных масел на полигоны железных

дорог является эффективным инструментом.

В заключении стоит отметить, что разработка программного продукта с применением машинного обучения для расче-

та поставок моторных масел на полигоны железных дорог обеспечит оптимизацию расходов и целевое использование денежных средств, а также позволит устрани-

нить возникновение рисков срыва эксплуатационной работы из-за отсутствия смазочных материалов на топливных складах.

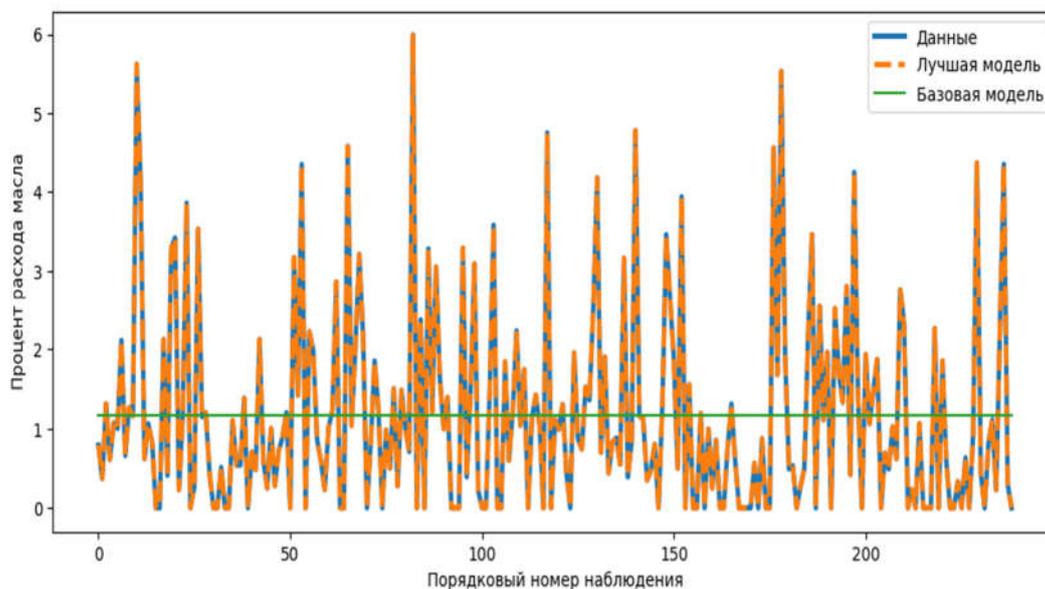


Рис. 1. График соответствия применяемым моделям
Fig. 1. The graph of compliance with the applied models

СПИСОК ИСТОЧНИКОВ

1. Распоряжение ОАО «РЖД» от 15 декабря 2011 № 2718р «Об утверждении Энергетической стратегии холдинга на период до 2015 года и на перспективу до 2030 года»
2. Методика расчета расхода моторного масла на эксплуатацию тягового подвижного состава от 11 апреля 2012 № 717р (в редакции распоряжения ОАО «РЖД» от 29 октября 2021 г. № 2349/р).
3. Мюллер, А. Введение в машинное обучение с помощью Python. Руководство для специалистов по работе с данными / А.Мюллер. – М.: Альфа-книга, 2017. - 244 с.

4. Вандер Плас, Дж. Python для сложных задач. Наука о данных и машинное обучение / Дж. Вандер Плас. – М.: Питер, 2017. - 393 с.
5. Вьюгин, В. В. Математические основы машинного обучения и прогнозирования / В.В. Вьюгин. - М.: МЦНМО, 2014. - 473 с.
6. Рашка, С. Python и машинное обучение / С. Рашка. - М.: ДМК Пресс, 2017. - 177 с.
7. Никулин, Е.А. Компьютерная геометрия и алгоритмы машинной графики / Е.А. Никулин. - М.: СПб: BHV, 2005. - 576 с
8. Роджерс, Д. Математические основы машинной графики / Д. Роджерс, Дж. Адамс. - М.: Мир; Издание 2-е, перераб. и доп., 2001. - 604 с.

REFERENCES

1. Russian Railways, Order No. 2718p. On Approval of the Holding's Energy Strategy for the Period up to 2015 and for the Future up to 2030; December 15, 2011.
2. Methodology for calculating engine oil consumption for the operation of traction rolling stock No. 717p; April 11, 2012.
3. Muller A. Introduction to machine learning using Python. A guide for data scientist. Moscow: Alpha-book; 2017.
4. Plas JV. Python Data Science Handbook. Moscow: Piter; 2017.

5. Vyugin VV. Mathematical grounds of machine learning and forecasting. Moscow: MCCME; 2014.
6. Raschka S, Mirjalili V. Python machine learning. Moscow: DMK Press; 2017.
7. Nikulin EA. Computer geometry and algorithms of machine graphics. Moscow: St. Petersburg: BHV; 2005.
8. Rogers D, Adams J. Mathematical elements for computer graphics. 2nd ed. Moscow: Mir; 2001.

Информация об авторах:

Лаушкин Эдуард Васильевич – аспирант, Российский университет транспорта (МИИТ), тел.: +79995990602.

Чернов Валерий Юрьевич – аспирант, Российский университет транспорта (МИИТ), тел.: +79035317482.

Laushkin Eduard Vasilyevich - Postgraduate student at Russian University of Transport (MIIT), phone: +79995990602.

Chernov Valery Yuryevich - Postgraduate student at Russian University of Transport (MIIT), phone: +79035317482.

Пашинин Валерий Алексеевич – доктор технических наук, профессор, Российский университет транспорта (МИИТ), тел.: +79163522997.

Pashinin Valery Alekseevich - Doctor of Technical Sciences, Professor, Russian University of Transport (MIIT), phone: +79163522997.

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 10.12.2024; одобрена после рецензирования 23.12.2024; принята к публикации 27.12.2024. 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 10.12.2024; approved after review on 23.12.2024; accepted for publication on 27.12.2024. 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 Council of the journal *Transport Engineering*.