

Научная статья

Статья в открытом доступе

УДК 004.942+629.113

doi: 10.30987/2782-5957-2026-5-63-73

## ФОРМИРОВАНИЕ ПОДХОДОВ ПРЕДИКТИВНОЙ АНАЛИТИКИ ТОиР АВТОМОБИЛЬНОГО ПАРКА НА ОСНОВЕ ВЫБОРА МОДЕЛЕЙ И АЛГОРИТМОВ

Юрий Александрович Заяц<sup>1</sup>, Николай Александрович Загородний<sup>2</sup>, Алла Сергеевна Семькина<sup>3</sup>, Александр Андреевич Пестов<sup>4✉</sup>

<sup>1</sup> Рязанское гвардейское высшее воздушно-десантное командное училище, Рязань, Россия

<sup>2,3,4</sup> Белгородский государственный технологический университет им. В.Г. Шухова, Белгород, Россия

<sup>1</sup> sajua@yandex.ru; <https://orcid.org/0009-0000-4122-5853>

<sup>2</sup> n.zagorodnij@yandex.ru; <https://orcid.org/0000-0002-2997-3282>

<sup>3</sup> fantarock@mail.ru; <https://orcid.org/0000-0003-4045-4237>

<sup>4</sup> a.pestov.a@yandex.ru; <https://orcid.org/0009-0003-8074-1043>

### Аннотация

Цель исследования – формирование прикладных подходов предиктивной аналитики ТОиР автомобильного парка на основе выбора моделей и алгоритмов, а также описания контура обучения и настройки моделей для достижения устойчивой точности прогнозирования.

Задача, решению которой посвящена статья. Сформировать прикладные подходы предиктивной аналитики технического обслуживания и ремонта (ТОиР) автомобильного парка с фокусом на выбор моделей и алгоритмов, обучение на подготовленных данных и настройку параметров для достижения устойчивой точности прогнозирования.

Методы исследования. Прогнозирование, математическое моделирование, статистический анализ, системный анализ, теория надежности, теория вероятности, теория управления.

Новизна работы. Теоретические и прикладные подходы к предиктивной аналитике ТОиР автомобильного парка, основанные на связке «постановка задачи → корректная временная выборка →

выбор модели → обучение и настройка → решение ТОиР».

Результаты исследования. Показано, что специфика автопарка (неоднородность режимов эксплуатации, дисбаланс событий, цензурирование наблюдений, конкуренция «плановая замена vs отказ») требует корректной постановки целевых событий, временной валидации, калибровки вероятностей и перевода прогнозов в решения с учетом стоимости ошибок.

Выводы: Предложена методика «данные → модель → решение», включающая интерпретируемые модели анализа времени до события и высокоточные модели на табличных признаках (градиентный бустинг), а также практические схемы внедрения и мониторинга качества в эксплуатации.

**Ключевые слова:** предиктивная аналитика, ТОиР, автопарк, прогноз, анализ, выживаемость, калибровка вероятностей, RUL, аномалии.

**Благодарность:** Работа выполнена в рамках реализации федеральной программы поддержки университетов «Приоритет 2030» с использованием оборудования на базе Центра высоких технологий БГТУ им. В.Г. Шухова.

Ссылка для цитирования:

Заяц Ю.А. Формирование подходов предиктивной аналитики ТОиР автомобильного парка на основе выбора моделей и алгоритмов / Ю.А. Заяц, Н.А. Загородний, А.С. Семькина, А.А. Пестов // Транспортное машиностроение. – 2026. - № 5. – С. 63-73. doi: 10.30987/2782-5957-2026-5-63-73.

Original article

Open Access Article

# FORMATION OF APPROACHES TO PREDICTIVE ANALYSIS OF AUTOMOBILE FLEET MAINTENANCE BASED ON THE CHOICE OF MODELS AND ALGORITHMS

Yury Aleksandrovich Zayats<sup>1</sup>, Nikolay Aleksandrovich Zagorodny<sup>2</sup>, Alla Sergeevna Semykina<sup>3</sup>, Aleksandr Andreevich Pestov<sup>4</sup>✉

<sup>1</sup> Ryazan Guards Higher Airborne Command Military College, Ryazan, Russia

<sup>2,3,4</sup> Belgorod State Technological University named after V.G. Shukhov, Belgorod, Russia

<sup>1</sup> sajua@yandex.ru; <https://orcid.org/0009-0000-4122-5853>

<sup>2</sup> n.zagorodnij@yandex.ru; <https://orcid.org/0000-0002-2997-3282>

<sup>3</sup> fantarock@mail.ru; <https://orcid.org/0000-0003-4045-4237>

<sup>4</sup> a.pestov.a@yandex.ru; <https://orcid.org/0009-0003-8074-1043>

## Abstract

The study objective is to develop applied approaches to predictive analytics of automobile fleet maintenance based on the selection of models and algorithms, as well as the description of the learning contour and model settings to achieve sustainable forecasting accuracy.

The task to which the paper is devoted is to form applied approaches for predictive analytics of automobile fleet maintenance with a focus on the selection of models and algorithms, training on the prepared data, and parameter tuning to achieve sustainable forecasting accuracy.

Research methods. Forecasting, mathematical modeling, statistical analysis, system analysis, reliability theory, probability theory, management theory.

The novelty of the work includes theoretical and applied approaches to predictive analytics of automobile fleet maintenance based on the following sequence "problem statement → correct time sampling → model

selection → training and configuration → maintenance implementation".

Study results. It is shown that the specifics of the fleet (heterogeneity of operating modes, imbalanced events, censoring of observations, planned replacement vs failure competition) require the correct formulation of target events, time validation, calibration of probabilities and the transfer of forecasts into solutions taking into account the cost of errors.

Conclusions: The technique "data → model → solution" is proposed, which includes interpreted time-to-event analysis models and high-precision models based on tabular features (gradient boosting), as well as practical schemes for implementing and monitoring quality in operation.

**Keywords:** predictive analytics, maintenance, automobile fleet, forecast, analysis, survival, probability calibration, RUL, anomalies.

**Acknowledgements:** The paper is written as a part of implementation of the federal university support program "Priority 2030" using the equipment based on the High Technology Center of BSTU named after V.G. Shukhov.

## Reference for citing:

Zayats YuA, Zagorodny NA, Semykina AS, Pestov AA. Formation of approaches to predictive analysis of automobile fleet maintenance based on the choice of models and algorithms. *Transport Engineering*. 2026;5:63-73. doi: 10.30987/2782-5957-2026-5-63-73.

## Введение

Предиктивная аналитика в ТОиР автомобильного парка рассматривается как инструмент перехода от реагирования на отказ к управлению риском и ресурсом узлов. В отличие от многих промышленных сценариев, автопарк характеризуется высокой вариативностью режимов эксплуатации (город/трасса, климат, загрузка, стиль вождения), разнородностью состава парка и неполной наблюдаемостью (не все транспортные средства оснащены одинаковыми датчиками, телематика может быть разреженной). Кроме того, события обслуживания нередко «перехватывают»

отказы: профилактическая замена скрывает момент потенциального отказа, что порождает цензурирование и конкурирующие события.

Практическая сложность предиктивного ТОиР заключается не столько в выборе «самого точного» алгоритма, сколько в согласовании постановки задачи (что считаем событием и на каком горизонте), процедуры обучения (без утечки и с учетом временной структуры данных), метрик качества, отражающих стоимость ошибок, и правил принятия решений (как прогноз превращается в действие ТОиР). Эта про-

блема особенно актуальна в условиях цифровизации автотранспортных предприятий и роста объемов собираемых данных с бортовых систем.

Существующие подходы к предиктивному обслуживанию часто ограничиваются описанием алгоритмов машинного обучения без учета специфики транспортной отрасли. Анализ научных публикаций показывает недостаток комплексных мето-

дик, связывающих выбор моделей с бизнес-требованиями и эксплуатационными ограничениями. Целью данного исследования является формирование прикладных подходов предиктивной аналитики ТОиР автомобильного парка на основе выбора моделей и алгоритмов, а также описания контура обучения и настройки моделей для достижения устойчивой точности прогнозирования.

## Материалы, модели, эксперименты и методы

Для автомобиля (или узла) в момент времени ( $t$ ) сформирован вектор признаков ( $x_t$ ). Для заданного горизонта  $\Delta$  (дни, км,

моточасы) определяется целевая вероятность:

$$p_\tau(x_t) = P(\text{event} \in [t, t + \tau] | x_t). \quad (1)$$

Событие *event* должно быть определено так, чтобы оно соответствовало управленческому действию. На практике выделяют:  $E_1$ : «жесткое» событие (останов/эвакуация/невыпуск);  $E_2$ : внеплановый ремонт по неисправности;  $E_3$ : замена узла (с разделением причин: регламент/диагностика/поломка) [1-3].

Постановка  $p_\tau$  удобна тем, что прогноз напрямую переводится в правило назначения работ (порог/ранжирование), а качество легко измерять на исторических данных [4-7]. Однако при неверном определении события модель будет оптимизировать не отказ, а, например, «шаблон сервисной политики», что снижает переносимость между подразделениями и периодами.

В автопарке часто наблюдается цензурирование: событие не наступило до конца наблюдения или объект «выпал» (продажа ТС, списание, смена телематиче-

ского оборудования) [8, 9]. Для таких данных корректна постановка «время до события» ( $T$ ) и работа с функциями:

- функция выживания: 
$$S(t) = \mathbb{P}(T > t), \quad (2)$$

- функция интенсивности (hazard): 
$$\lambda(t) = \lim_{\Delta t \rightarrow 0} \frac{\mathbb{P}(t \leq T < t + \Delta t | T \geq t)}{\Delta t} \quad (3)$$

Связь между ними:

$$S(t) = \exp\left(-\int_0^t \lambda(u), du\right) \quad (4)$$

Ключевой прикладной смысл: цензурированные объекты не нужно исключать – они содержат информацию о «выживании без события». Базовые методы: оценка *Kaplan-Meier* и модели Кокса [10].

Поскольку данные эксплуатации удобно анализировать с дискретным шагом (сутки/недели/кванты пробега), часто применяют дискретную интенсивность (*hazard*) по шагам ( $k$ ):

$$h_k = \mathbb{P}(T = k | T \geq k, x_k), \quad S_k = \prod_{j=1}^k (1 - h_j) \quad (5)$$

Тогда вероятность события на горизонте ( $K$ ) шагов:

$$P(T \leq K) = 1 - S_K = 1 - \prod_{j=1}^K (1 - h_j). \quad (6)$$

Данный подход позволяет:

- использовать табличные алгоритмы (включая бустинг) для оценки  $h_k$ ;
- учитывать «не наступило событие до момента ( $k$ )» без потери данных;
- получать как риск на горизонте, так и кривую риска во времени.

*RUL* (остаточный ресурс) как оценка ожидаемого времени до события, в простейшем виде:

$$\overline{RUL}(t) = \mathbb{E}[T - t | x_t]. \quad (7)$$

На практике в автопарке *RUL* удобен, когда ремонтная политика ориентирована на ресурс детали (например, АКБ при наличии параметров напряжения и стати-

стики запусков; узлы, где деградация выражается через температурные или нагрузочные индикаторы). Ограничение: при активной профилактике модель может предсказывать «время до замены по правилам», а не «время до отказа». Поэтому для *RUL* особенно важны: раздельная маркировка причин замены и учет цензурирования.

Данные автопарка обычно поступают из нескольких систем: телематика/OBD, учет ТОиР, склад/запчасти, эксплуатационный контекст. Для предиктивного моделирования необходимо обеспечить два свойства: временная причинность (в признаках только то, что известно на момент прогноза) и воспроизводимость (одинаковая логика формирования выборки при переобучении).

На рис. 1 представлена схема конвейера «данные → признаки → цель» для предиктивного ТОиР.

Пусть  $s(\tau)$  – наблюдаемый сигнал (температура, напряжение, обороты) во времени внутри окна  $[t - \delta, t]$ . Типичные агрегаты:

- среднее:

$$\bar{s} = \frac{1}{\delta} \int_{t-\delta}^t s(\tau) d\tau$$

- максимум:

$$s_{\max} = \max_{\tau \in [t-\delta, t]} s(\tau)$$

- доля времени выше порога ( $c$ ):

$$\frac{1}{\delta} \int_{t-\delta}^t \mathbb{I}(s(\tau) > c) d\tau$$

- тренд (простая аппроксимация):

$$newDTCt, \Delta = \sum_{d \in D} 1[DTC_d \text{ в окне и отсутствовал ранее в контролируемом периоде}]$$

Практический смысл: агрегаты снижают чувствительность к разреженности телематики, улучшают устойчивость к шуму и позволяют применять сильные табличные модели без обязательного использования глубоких последовательных сетей.

Ключевое правило: в момент ( $t$ ) модель не должна видеть ничего, что формируется после события (закрытие наряда, фактическое списание запчастей, постфак-

$$k = \operatorname{argmin}_k \int_{t-\delta}^t (s(\tau) - (k\tau + b))^2 d\tau$$

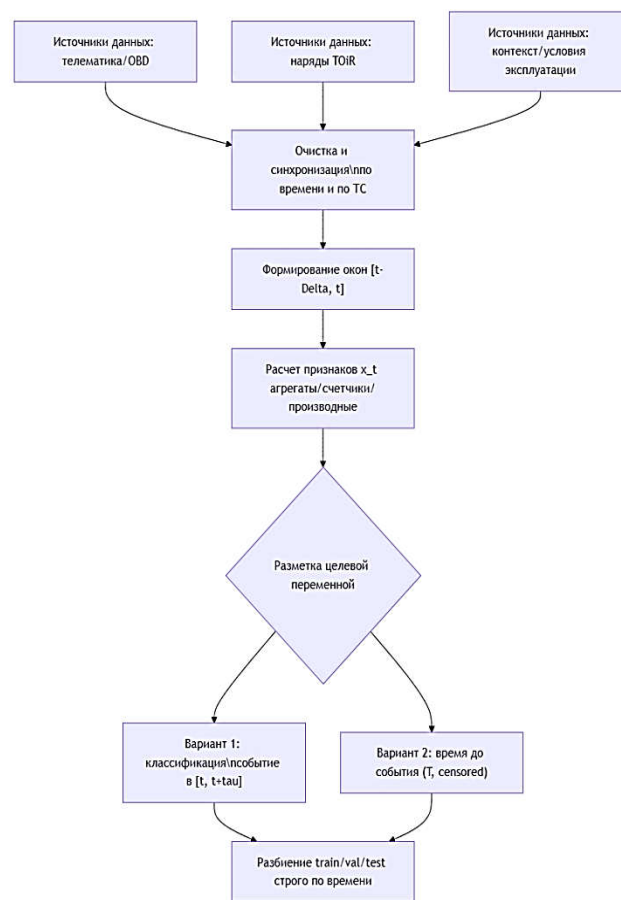


Рис. 1. Схема конвейера «данные → признаки → цель» для предиктивного ТОиР  
Fig. 1. Pipeline scheme "data → features → target" for predictive maintenance

Для диагностических событий (например, появление *DTC*) применяются счетчики и «новизна»:

тум-диагностика). Иначе качество будет завышено и не воспроизводимо в эксплуатации.

Удобная практическая процедура – формальный «аудит признаков»:

- список всех признаков и время их появления;
- для каждого признака – проверка, не использует ли он данные будущего;
- тест на утечку: обучить простую модель только на подозрительных полях и

проверить, не возникает ли «слишком высокая» точность.

Для автопарка полезно вводить простые проверки: – монотонность пробега/моточасов (исключение откатов и неверных точек); – физические диапазоны (температуры, напряжение); – доля пропусков по датчикам и по ТС; – консистентность между источниками (например, пробег на момент наряда vs телематика).

Такие проверки не являются «дополнительной опцией»: они предотвращают обучение на артефактах, которые исчезают при смене устройства или поставщика телематики.

Выбор модели должен быть привязан к типу задачи, доступности данных, цене ошибок и требованиям к интерпретируемости.

Интерпретируемые *baseline*-модели (анализ надежности)

- *Kaplan-Meier* – сравнение групп по «выживаемости» при цензурировании [11].

- *Cox proportional hazards* – интерпретируемая модель факторов риска [10]:

$$\lambda(t | x) = \lambda_0(t) \exp(\beta T x). \quad (8)$$

Для *Cox* используется частичная правдоподобность:

$$L(\beta) = \prod_{i: \delta_i=1} \frac{\exp(\beta^T x_i)}{\sum_{j \in R_i} \exp(\beta^T x_j)}, \quad (9)$$

где  $\delta_i$  – индикатор наступления события,  $R_i$  – множество объектов «под риском» в момент события [10].

Практическая роль *baseline*:

- проверка здравого смысла (знаки влияния факторов);
- выявление доминирующих факторов эксплуатации (режимы, перегревы, напряжение);
- базовая модель для требований «объяснимо и просто».

Для типичного автопаркового сценария «оконные агрегаты + категориальные признаки + история» наиболее эффективны модели класса *GBDT* (например, *XGBoost*) [12]. Их преимущества: – сильная работа на табличных данных; – моделирование нелинейностей и взаимодей-

ствий; – высокая скорость инференса и промышленная применимость.

Обобщенно бустинг минимизирует функционал:

$$\min_f \sum_{i=1}^n \ell(y_i, f(x_i)) + \Omega(f) \quad (10)$$

где  $\ell$  – функция потерь (например, *logloss*),  $\Omega$  – регуляризация. В деревьях это реализуется пошаговым добавлением базовых моделей (деревьев), уменьшающих градиент ошибки [13].

Если доступен плотный поток телематики и важны временные паттерны деградации, применимы *LSTM*-подходы [14,15]. Однако для автопарка их внедрение оправдано, когда: – телематика стабильна по качеству и частоте; – данных достаточно много по однотипным ТС/узлам; – есть регламент мониторинга дрейфа и тестирования.

Во многих случаях «агрегирование по окнам + *GBDT*» дает более устойчивое качество при меньшей сложности эксплуатации.

Для эксплуатации важны ответы «почему риск вырос» и «какие факторы стали триггером». На практике применяют методы интерпретации предсказаний, включая подходы семейства *SHAP* [16]. При этом объяснимость должна сопровождаться анти-утечками: иначе модель будет «объяснять» будущее событие через косвенные учетные поля.

Ниже, на рис. 2, приведена компактная схема выбора (не как формальный стандарт, а как прикладная рекомендация).

Обучение моделей и настройка параметров происходит в несколько этапов [17, 18]:

1. Временная валидация как обязательное условие

Требование эксплуатации - имитировать будущее:

- обучение на периоде  $[T_0, T_1]$ ,
- валидация на  $(T_1, T_2]$ ,
- тест на  $(T_2, T_3]$ .

Случайное разбиение строк приводит к утечке, особенно если один и тот же автомобиль представлен множеством близких окон.

## 2. Борьба с дисбалансом: взвешивание и стоимость ошибок

Для отказов доля положительного класса может быть 0,1...5%. Тогда целесообразны:

- взвешивание классов;
- контроль метрик  $PR$ -семейства;
- обучение под целевую стоимость ошибок.

Взвешенная бинарная кросс-энтропия:

$$L = - \sum_{i=1}^n (\omega_1 y_i \log \hat{p}_i + \omega_0 (1 - y_i) \log (1 - \hat{p}_i)), \quad \omega_1 > \omega_0. \quad (11)$$

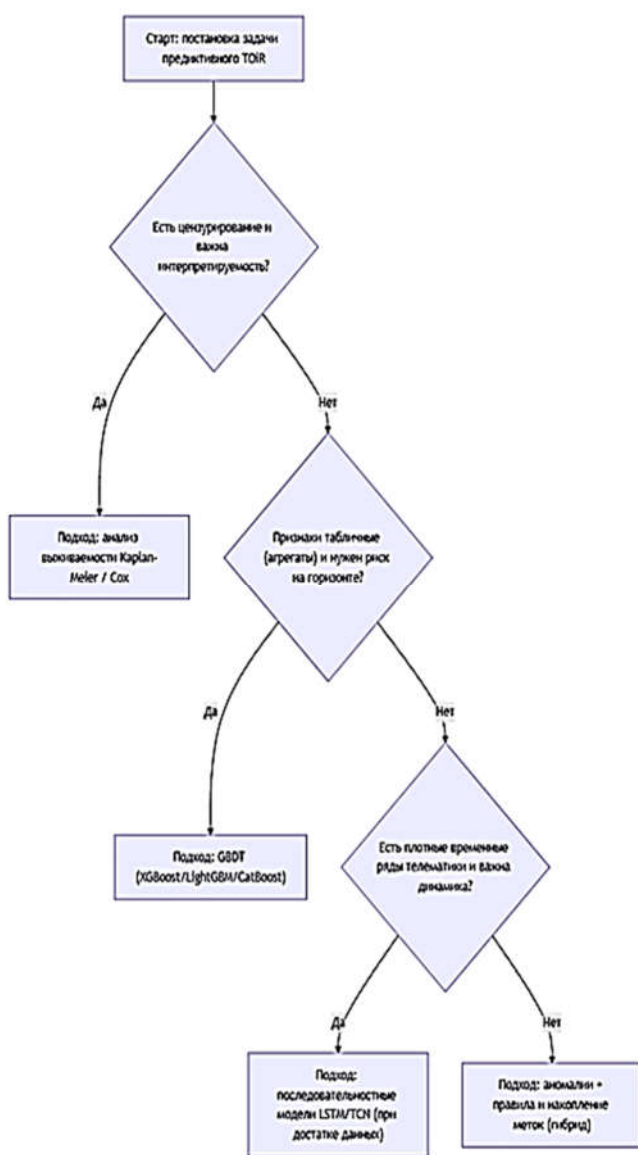


Рис. 2. Матрица выбора подхода для предиктивного ТОиР

Fig. 2. Decision matrix for approach selection in predictive maintenance

## 3. Калибровка вероятностей как мост между $ML$ и управлением ТОиР

Даже сильные модели дают некалиброванные вероятности; это мешает устойчивому выбору порогов. Показатель качества вероятностей – *Brier score*:

$$BS = \frac{1}{n} \sum_{i=1}^n (\hat{p}_i - y_i)^2 \quad (12)$$

На практике калибровку выполняют на отложенной временной валидации и проверяют стабильность по сезонам/месяцам.

## 4. Настройка гиперпараметров без переобучения

Для *GBDT* безопасный контур:

- фиксируется схема временного разбиения;
- ограничивается сложность (глубина, минимальный размер листа);
- применяется *early stopping*; проводится финальная проверка на полностью отложенном периоде.

## 5. Метрики: как избежать «метрик ради метрик».

Для практики ТОиР полезно одновременно измерять:

- качество ранжирования (кого брать в ремонт первым):  $PR-AUC$ ,  $precision@K$ ,  $recall@K$ ;
- качество вероятностей:  $logloss$ ,  $Brier score$ ;
- стабильность: метрики по времени (например, по месяцам).

Для ограниченного ресурса сервиса ключевой показатель может быть не «средняя» метрика, а качество в верхнем хвосте риска ( $TOP-N$ ).

## 6. Проверка на «сдвиг распределений» и дрейф

Автопарк меняется: сезон, маршруты, состав парка, датчики. Поэтому важен контроль дрейфа признаков. Один из простых индикаторов – *Population Stability Index (PSI)*:

$$PSI = \sum_b (p_b - q_b) \ln \frac{p_b}{q_b}, \quad (13)$$

где  $p_b$  – доля наблюдений в обучающем периоде,  $q_b$  – доля в текущем периоде.  $PSI$  помогает оперативно выявлять «сломан-

ные датчики», смену телематической прошивки или смену режима эксплуатации.

Перевод прогнозов в решения ТОиР возможно произвести несколькими вариантами:

1. Пороговое правило через ожидаемые затраты

Пусть модель дает  $\hat{p}_\tau$  - вероятность события на горизонте  $\tau$ . Тогда решение о превентивном действии:

Выполнять действие, если

$$\hat{p}_\tau C_{fail} > C_{pm} + C_{fp}, \quad (14)$$

где

•  $C_{fail}$  – потери при отказе (простой, эвакуация, штрафы, вторичный ущерб),

•  $C_{pm}$  – стоимость профилактики/диагностики,

•  $C_{fp}$  – стоимость ложного срабатывания.

Отсюда порог:

$$\hat{p}_\tau > \frac{C_{pm} + C_{fp}}{C_{fail}}. \quad (15)$$

Это делает выбор порога воспроизводимым и привязанным к экономике (а не к «красоте» ROC-кривой).

2. Ограниченные ресурсы сервиса: ранжирование и оптимизация

Если сервис может обработать не более  $K$  автомобилей в неделю, рационально обслуживать TOP-K по ожидаемой выгоде. Для объекта  $i$ :

$$\Delta_i = \hat{p}_{\tau,i} C_{fail,i} - (C_{pm,i} + C_{fp,i}). \quad (16)$$

Правило: выбрать  $K$  объектов с максимальными  $\Delta_i$ , где  $\Delta_i > 0$ . Это обеспечивает согласование предиктивной модели с ресурсными ограничениями предприятия.

3. Привязка к запасам и логистике запчастей

Для реального эффекта в ТОиР важно не только «предсказать отказ», но и обеспечить готовность ремонта:

- прогноз высокого риска по узлу → резервирование слота в ремонтной зоне;
- прогноз по группе узлов → формирование заявки на склад/закупку;
- ранжирование по риску + срок поставки → приоритетность заказов.

Практически это реализуется через совместную шкалу приоритета

$$priority_i = \alpha \hat{p}_{\tau,i} + \beta leadtime_i + \gamma criticality_i, \quad (17)$$

где коэффициенты подбираются под процессы предприятия, а  $criticality$  отражает безопасность/влияние на выпуск.

4. От прогноза риска к оптимизации интервала профилактики

Если предприятие применяет профилактику раз в  $T$  (в днях/км), можно оценивать ожидаемые затраты на цикл. Пусть

$F(T) = P(T_{fail} \leq T)$  – вероятность отказа до профилактики. Тогда ожидаемые затраты на один цикл:

$$E[C(T)] = C_{pm} + C_{fail} F(T). \quad (18)$$

Нормируя на длительность цикла  $T$ , получаем средние затраты на единицу времени/пробега:

$$J(T) = \frac{C_{pm} + C_{fail} F(T)}{T}. \quad (19)$$

Задача практической оптимизации:

$$T^* = \arg \min_T J(T). \quad (20)$$

В предиктивном контуре  $F(T)$  может оцениваться моделью риска/выживаемости. Это связывает аналитическую часть с управленческим решением «как часто обслуживать» и дает измеримый экономический эффект без необходимости «угадать точный момент отказа».

Для критичных режимов (перегрев, падение давления, критические  $DTC$ ) применяют жесткие правила, а  $ML$  – для приоритизации менее очевидных случаев (рис. 3).

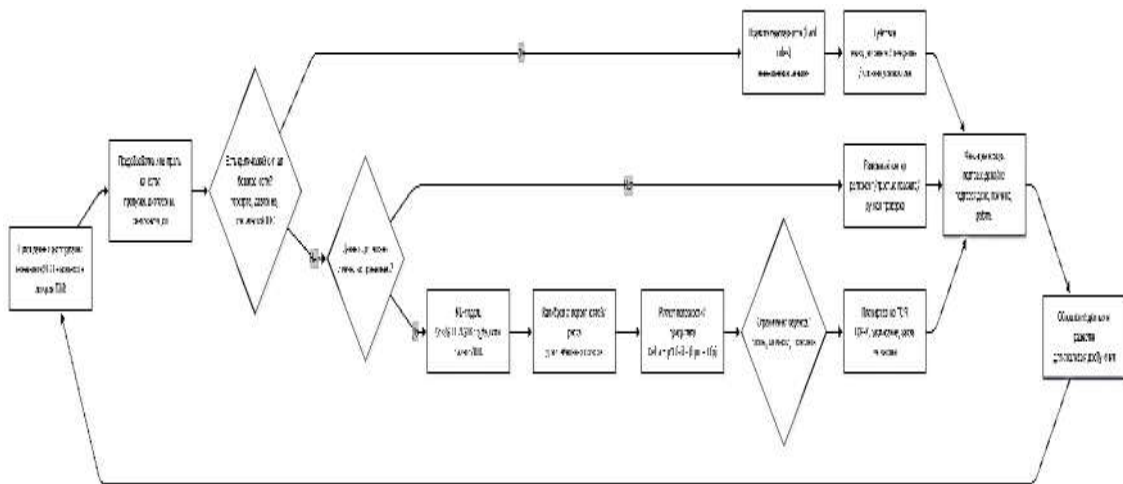


Рис. 3. Гибридная архитектура решений  
Fig. 3. Hybrid decision architecture

## Результаты

Такой подход снижает риски внедрения: безопасность не зависит от стабильности модели, а модель повышает эффективность использования сервисных ресурсов.

Чтобы предиктивная аналитика не оставалась «универсальной», полезно привязать постановку к типовым узлам и доступным сигналам:

1. АКБ и система электропитания (вероятность отказа запуска)

- Событие: *E2* (внеплановый заезд) или *E1* (невывод/не запуск).

- Признаки: минимальное напряжение, разброс напряжения, число запусков, доля коротких поездок, температура окружающей среды.

- Модель: *GBDT* для риска на горизонте + калибровка; *baseline – Cox* для интерпретации факторов.

- Действие: диагностика АКБ/генератора при превышении порога, планирование замены при устойчивом росте риска.

2. Перегрев и система охлаждения (риски тяжелых отказов)

- Событие: *E1* (останов/перегрев) как наиболее значимое по ущербу.

- Признаки: время выше температурного порога, число перегревов, нагрузочные режимы, скорость, контекст (жара/пробки).

- Контур: правила безопасности (немедленная реакция на перегрев) + *ML*

для выявления «предперегретых» паттернов и профилактики.

3. Тормозная система и стиль эксплуатации

- Событие: *E3* (замена элементов) или *E2* при скрипах/вибрациях.

- Признаки: частота резких торможений, городская доля, пробег после последней замены, масса/загрузка (если доступно).

- Решение: прогноз более точен при нормировке на режим эксплуатации; полезно ранжирование и прогноз «ускоренного износа».

Такие «узловые» сценарии повышают прикладную ценность статьи: показывают, как одна и та же методика адаптируется под разные подсистемы и разные типы событий.

Предиктивное ТОиР – это цикл, а не разовый проект. Минимальный регламент должен включать:

1. Мониторинг данных: доля пропусков телематики, дрейф распределений ключевых признаков, изменения частот *DTC*.

2. Мониторинг качества: метрики на скользящем временном окне, стабильность калибровки вероятностей.

3. Триггеры переобучения: деградация метрик, смена состава парка, изменение регламентов, обновление оборудования.

4. Версионирование: версия данных/признаков/модели/порогов решений – обязательна для воспроизводимости.

### Обсуждение/Заключение

Сформированы теоретические и прикладные подходы к предиктивной аналитике ТОиР автомобильного парка, основанные на связке «постановка задачи → корректная временная выборка → выбор модели → обучение и настройка → решение ТОиР». Показано, что для автопарка принципиальны учет цензурирования и конкурирующих событий, временная валидация и калибровка вероятностей. В качестве практического ядра для большинства сценариев рекомендована комбинация интерпретируемых baseline-моделей анализа времени до события (*Kaplan-Meier, Cox*) и высокоточных табличных моделей класса градиентного бустинга с обязатель-

5. Обратная связь: фиксация результата рекомендаций (подтвердилось/не подтвердилось) – ключевой источник улучшения разметки и качества модели.

ной процедурой контроля утечек и объяснимости.

Практическая ценность предиктивной аналитики ТОиР достигается при формализации действий через ожидаемые затраты, ранжирование в условиях ограниченных ресурсов сервиса, а также при наличии мониторинга дрейфа и качества модели в эксплуатации. Перспективы дальнейших исследований включают: разработку гибридных моделей, интегрирующих физические законы износа и статистическое обучение; исследование методов трансферного обучения для разнородных парков; оптимизацию совместного планирования обслуживания и запасов запчастей на основе прогнозной аналитики.

### СПИСОК ИСТОЧНИКОВ

1. ГОСТ 18322–2016. Система технического обслуживания и ремонта техники. Термины и определения. М.: Стандартинформ, 2017.
2. ГОСТ Р 27.002–2015. Надежность в технике. Термины и определения. М.: Стандартинформ, 2016.
3. ISO 55000:2014. Asset management – Overview, principles and terminology. Geneva: ISO, 2014.
4. ISO 17359:2018. Condition monitoring and diagnostics of machines – General guidelines. Geneva: ISO, 2018.
5. Гераон А. Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow / пер. с англ. М.: Диалектика, 2020.
6. Маккинни У. Python и анализ данных / пер. с англ. СПб.: Питер, 2019.
7. Хасты Т., Тибширани Р., Фридман Дж. Элементы статистического обучения / пер. с англ. М.: ДМК Пресс, 2017.
8. Бишоп К. Распознавание образов и машинное обучение / пер. с англ. М.: ДМК Пресс, 2016.
9. SAE International. SAE J1939 (Serial Control and Communications Heavy Duty Vehicle Network). Warrendale, PA: SAE International.
10. Cox D. R. Regression models and life-tables // Journal of the Royal Statistical Society: Series B (Methodological). 1972. Vol. 34, No. 2. P. 187–220. DOI: 10.1111/j.2517-6161.1972.tb00899.x.
11. Kaplan E. L., Meier P. Nonparametric estimation from incomplete observations // Journal of the American Statistical Association. 1958. Vol. 53, No. 282. P. 457–481. DOI: 10.1080/01621459.1958.10501452.
12. Chen T., Guestrin C. XGBoost: A scalable tree boosting system // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16). New York: ACM, 2016. P. 785–794. DOI: 10.1145/2939672.2939785.
13. Ke G. et al. LightGBM: A highly efficient gradient boosting decision tree // Advances in Neural Information Processing Systems. 2017. Vol. 30. P. 3146–3154.
14. Prokhorenkova L. et al. CatBoost: unbiased boosting with categorical features // Advances in Neural Information Processing Systems. 2018. Vol. 31. P. 6638–6648.
15. Hochreiter S., Schmidhuber J. Long short-term memory // Neural Computation. 1997. Vol. 9, No. 8. P. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735
16. Lundberg S. M., Lee S.-I. A unified approach to interpreting model predictions // Advances in Neural Information Processing Systems. 2017. Vol. 30. P. 4765–4774.
17. Семькина, А.С. Неисправности современных автомобилей. Применение компьютерных программ для расчета технических параметров поршня // В сборнике: Международная научно-техническая конференция молодых ученых БГТУ им. В.Г. Шухова Белгородский государ-

ственный технологический университет им. В.Г. Шухова. 2016. С. 1751-1756.

18. Семькина, А.С. Повышение эффективности эксплуатации транспортного комплекса горно-

обогатительных комбинатов / А.С. Семькина, Н.А. Загородний, А.А. Конев // Мир транспорта и технологических машин. 2018. № 1 (60). С. 134-139.

## REFERENCES

1. GOST 18322-2016. Maintenance and repair system of engineering. Terms and definitions. Moscow: Standartinform; 2017.
2. GOST R 27.002-2015. Dependability in technics. Terms and definitions. Moscow: Standartinform; 2016.
3. ISO 55000:2014. Asset management: overview, principles and terminology. Geneva: ISO; 2014.
4. ISO 17359:2018. Condition monitoring and diagnostics of machines: general guidelines. Geneva: ISO; 2018.
5. Geraon A. Applied machine learning using Scikit-Learn and TensorFlow. Moscow: Dialektika; 2020.
6. McKinney U. Python and data analysis. St. Petersburg: Peter; 2019.
7. Hastie T, Tibshirani R, Friedman J. Elements of statistical learning. Moscow: DMK Press; 2017.
8. Bishop K. Pattern recognition and machine learning. Moscow: DMK Press; 2016.
9. Warrendale PA. SAE International. SAE J1939 (Serial Control and Communications Heavy Duty Vehicle Network). SAE International; 2003.
10. Cox DR. Regression models and life-tables. Journal of the Royal Statistical Society: Series B (Methodological). 1972;34(2):187-220. DOI: 10.1111/j.2517-6161.1972.tb00899.x.
11. Kaplan EL, Meier P. Nonparametric estimation from incomplete observations. Journal of the American Statistical Association. 1958;53(282):457-481. DOI: 10.1080/01621459.1958.10501452.
12. Chen T, Guestrin C. XGBoost: a scalable tree boosting system. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16). New York: ACM, 2016;785-794. DOI: 10.1145/2939672.2939785.
13. Ke G. LightGBM: a highly efficient gradient boosting decision tree. Advances in Neural Information Processing Systems. 2017;30:3146-3154.
14. Prokhorenkova L. CatBoost: unbiased boosting with categorical features. Advances in Neural Information Processing Systems. 2018;31:6638-6648.
15. Hochreiter S, Schmidhuber J. Long short-term memory. Neural Computation. 1997;9(8):1735-1780. DOI: 10.1162/neco.1997.9.8.1735
16. Lundberg SM, Lee S-I. A unified approach to interpreting model predictions. Advances in Neural Information Processing Systems. 2017;30:4765-4774.
17. Semykina, AS. Malfunctions of modern cars. The use of computer programs for calculating the technical parameters of the piston. In: International Scientific and Technical Conference of Young Scientists of BSTU named after VG. Shukhov; Belgorod State Technological University named after VG. Shukhov. Belgorod; 2016.
18. Semykina AS, Zagorodny NA, Konev AA. Improving the efficiency of operation of ore mining and processing enterprise transport complexes. Transport and Technological Cars. 2018;1(60):134-139.

## Информация об авторах:

**Зяц Юрий Александрович** – доктор технических наук, профессор кафедры математических и естественно-научных дисциплин Рязанского высшего воздушно-десантного командного ордена Суворова дважды Краснознаменного училища имени генерала армии В.Ф. Маргелова.

**Загородний Николай Александрович** – доктор технических наук, доцент, директор Транспортно-технологического института Белгородского госу-

**Zayats Yury Aleksandrovich** – Doctor of Technical Sciences, Professor of the Department of Mathematics and Natural Sciences of Ryazan Guards Higher Airborne Command Military College.

**Zagorodny Nikolay Aleksandrovich** – Candidate of Technical Sciences, Associate Professor, Head of the Department of Operation and Management of Motor Transport at BSTU named after V.G. Shukhov, phone: 89202014925.

дарственного технологического университета им. В.Г. Шухова, тел. 89202014925.

**Семькина Алла Сергеевна** – кандидат технических наук, доцент кафедры «Эксплуатация и организация движения автотранспорта» Белгородского государственного технологического университета им. В.Г. Шухова, тел. 89040943937.

**Пестов Александр Андреевич** – аспирант кафедры «Эксплуатация и организация движения автотранспорта», тел. +7(901)702-72-97.

**Semykina Alla Sergeevna** – Candidate of Technical Sciences, Assistant of the Department of Operation and Organization of Motor Transport at Belgorod State Technological University named after V.G. Shukhov; phone: 89040943937.

**Pestov Aleksandr Andreevich** – Postgraduate student at the Department of Operation and Organization of Motor Transport, phone: +7(901)702-72-97.

**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 28.01.2026; одобрена после рецензирования 08.04.2026; принята к публикации 27.04.2026. Рецензент – Антипин Д.Я., кандидат технических наук, доцент кафедры «Подвижной состав железных дорог», член редсовета журнала «Транспортное машиностроение».**

**The article was submitted to the editorial office on 28.01.2026; approved after review on 08.04.2026; accepted for publication on 27.04.2026. The reviewer is Antipin D.Ya., Candidate of Technical Sciences, Associate Professor of the Department of Railway Rolling Stock, member of the Editorial Council of the journal *Transport Engineering*.**



***В Брянском государственном техническом университете в 2026 году продолжается приём на новую специальность  
23.05.03 – Подвижной состав железных дорог,  
специализация «Технология производства и ремонта подвижного состава»***

*Подготовка предусматривает освоения фундаментальных основ конструкции, технического обслуживания и ремонта подвижного состава железных дорог с применением предиктивной аналитики, систем искусственного интеллекта и работы с большими объемами данных. Обучение организовано в интересах крупнейших предприятий в области обслуживания и ремонта подвижного состава таких, как ООО «Локотех», ОАО «РЖД», ООО «Новая вагоноремонтная компания» и другие.*

*Начиная со второго курса обучения студентам предоставляется возможность оплачиваемой стажировки на структурных подразделениях компаний с целью приобретения практических навыков необходимых для освоения профессий технолога и инженера. В рамках освоения программы значительное внимание уделяется современным методам прогнозирования технического состояния подвижного состава, системам массового обслуживания и ремонта сложных технических систем, прогнозирования фактического состояния ответственных узлов подвижного состава и оценке рисков возникновения аварийных ситуаций.*

*Приобретённые по программе специалитета компетенции позволят обучающимся стать высококвалифицированными специалистами, которые смогут применить полученные знания и навыки на практике, участвуя в реализации стратегических проектов по развитию железнодорожной инфраструктуры страны.*