



2.9.5 – эксплуатация автомобильного транспорта

ИНТЕЛЛЕКТУАЛЬНЫЙ МЕТОД ФОРМИРОВАНИЯ ПАРКА ГРУЗОВЫХ АВТОМОБИЛЕЙ

✉¹ **Фирсова Светлана Юрьевна**,
старший преподаватель кафедры «Автомобильные перевозки», Волгоградский государственный технический университет, г. Волгоград, e-mail: firsova.svetlana@mail.ru

Скоробогатченко Дмитрий Анатольевич,
к.т.н., профессор кафедры «Системы автоматизированного проектирования и поискового конструирования», Волгоградский государственный технический университет, г. Волгоград.

Ширяев Сергей Александрович,
к.т.н., доцент кафедры «Автомобильные перевозки» Волгоградский государственный технический университет, г. Волгоград.

Зеликов Владимир Анатольевич,
д.т.н., профессор кафедры организации перевозок и безопасности движения, Воронежский государственный лесотехнический университет имени Г.Ф. Морозова, г. Воронеж.

Аннотация. Формирование рациональной структуры парка грузовых автомобилей определяет способность автотранспортного предприятия выполнять перевозки с требуемым уровнем сервиса при минимальных затратах. Традиционные методы, основанные на нормативных показателях и усреднённых коэффициентах, не учитывают индивидуальные особенности перевозок и скрытые закономерности, присутствующие в исторических данных. В работе предложен интеллектуальный метод формирования парка, объединяющий классификацию типов грузовых автомобилей на основе машинного обучения с оптимизационным расчётом методом

INTELLIGENT METHOD FOR FORMING A FARM OF TRUCKS

✉¹ **Firsova Svetlana Yuryevna**,
senior lecturer of the automobile transportation department, Volgograd state technical university, Volgograd, e-mail: firsova.svetlana@mail.ru

Skorobogatchenko Dmitry Anatolyevich,
doctor of technical sciences, professor of the computer-aided design systems and exploratory engineering department, Volgograd state technical university, Volgograd.

Shiryaev Sergey Alexandrovich,
candidate of technical sciences, associate professor of the automobile transportation department, Volgograd state technical university, Volgograd.

Zelikov Vladimir Anatolyevich,
doctor of technical sciences, professor of the organization of transportation and traffic safety, Voronezh state forestry university named after G.F. Morozov, Voronezh.

Annotation. The formation of a rational truck fleet structure determines the ability of a motor transport enterprise to perform transportation with the required level of service at minimal cost. Traditional methods based on standard indicators and average coefficients do not account for individual transportation characteristics and hidden patterns present in historical data. This paper proposes an intelligent fleet formation method combining truck type classification based on machine learning with optimization calculation using linear programming. The public SCMS Delivery History dataset (2830 records of road transport) was used. For each truck type, the 75th percentile of the actual load factor was calculated, allowing differentiated standards

линейного программирования. Использован публичный датасет *SCMS Delivery History* (2830 записей автомобильных перевозок). Для каждого типа грузового автомобиля вычислен 75-й перцентиль фактического коэффициента использования грузоподъёмности, что позволило получить дифференцированные нормативы. Выполнено обучение четырёх моделей классификации: логистическая регрессия, случайный лес, градиентный бустинг, нейронная сеть. Результаты. Лучшие результаты показала модель градиентного бустинга с *F1-score* 0,89, точностью классификации 88-93 %. Предложенный метод обеспечивает снижение эксплуатационных затрат на 53% и сокращение необходимого парка на 50% по сравнению с традиционным автоматизированным подходом при сохранении объёма перевозок. Коэффициент использования грузоподъёмности повышен с 75 % до 82-85 %. Интеграция машинного обучения и оптимизации позволяет извлекать скрытые закономерности из исторических данных, учитывать сезонность, маршрутную структуру и индивидуальные особенности заказов. Разработанный интеллектуальный метод может быть внедрён в промышленные системы управления парком грузовых автомобилей для автоматизированного формирования рекомендаций по структуре парка.

Ключевые слова: ПАРК ГРУЗОВЫХ АВТОМОБИЛЕЙ, МАШИННОЕ ОБУЧЕНИЕ, ГРАДИЕНТНЫЙ БУСТИНГ, ЛИНЕЙНОЕ ПРОГРАММИРОВАНИЕ, КОЭФФИЦИЕНТ ИСПОЛЬЗОВАНИЯ ГРУЗОПОДЪЁМНОСТИ, СЕЗОННОСТЬ СПРОСА, ОПТИМИЗАЦИЯ ПАРКА.

to be obtained. Four classification models were trained: logistic regression, random forest, gradient boosting, and neural network. The gradient boosting model demonstrated the best results with an *F1-score* of 0.89 and classification accuracy of 88-93 %. The proposed method reduces operating costs by 53 % and reduces the required fleet size by 50 % compared to the traditional automated approach while maintaining transportation volume. The load factor increased from 75 % to 82-85 %. The integration of machine learning and optimization enables the extraction of hidden patterns from historical data, accounting for seasonality, route structure, and individual order characteristics. The developed intelligent method can be implemented in industrial truck fleet management systems for automated fleet structure recommendations.

Keywords: TRUCK FLEET, MACHINE LEARNING, GRADIENT BOOSTING, LINEAR PROGRAMMING, LOAD FACTOR, DEMAND SEASONALITY, FLEET OPTIMIZATION.

¹ Автор для ведения переписки

1 Состояние вопроса исследования и актуальность работы

Формирование рациональной структуры парка грузовых автомобилей является ключевой задачей автотранспортного предприятия (АТП), определяющей его способность выполнять перевозки с требуемым уровнем сервиса при минимально возможных затратах. Ошибки в планировании структуры парка приводят либо к дефициту автомобилей, что вызывает невыполнение заявок и рост доли привлеченного транспорта, либо к избыточному количеству автомобилей, что увеличивает постоянные затраты и простои транспортных средств [1, 2].

Традиционные методы формирования парка, основанные на нормативных показателях и усреднённых коэффициентах, не учитывают индивидуальные особенности перевозок и скрытые

закономерности, присутствующие в исторических данных [3, 4]. Как отмечают исследователи [5, 6], существующие подходы к планированию парка можно классифицировать на нормативно-аналитические, статистико-прогнозные, имитационные, оптимизационные и методы на основе искусственного интеллекта. Каждый из этих подходов имеет ограничения: нормативно-аналитические методы не адаптируются к изменяющимся условиям, статистико-прогнозные требуют стационарности временных рядов, имитационное моделирование сложно в настройке, а оптимизационные методы чувствительны к точности входных параметров [7, 8].

В последние годы активно развиваются методы машинного обучения (*ML*) для решения задач транспортного планирования [9, 10]. Исследования показывают, что *ML*-модели способны выявлять нелинейные зависимости между признаками заказов и оптимальными параметрами подвижного состава [11, 12]. Однако применение только *ML*-моделей не обеспечивает формализованного учёта ограничений и целевых функций, характерных для задач планирования парка [13].

Актуальность темы усиливается следующими условиями: выраженная сезонность и непостоянство спроса; неоднородность грузопотоков и маршрутная вариативность; необходимость оперативного пересчета потребности в автомобилях при изменении планов перевозок; развитие цифровых технологий и переход к управлению на основе данных [14-16].

Цель исследования – разработка интеллектуального метода формирования парка АТП, обеспечивающего обоснованный выбор структуры парка грузовых автомобилей с учётом объёмов партий грузов, грузоподъёмности, коэффициента использования грузоподъёмности, сезонных колебаний и прогнозируемых изменений спроса.

Для достижения цели поставлены следующие задачи: анализ существующих методов формирования парка и моделей машинного обучения; разработка структуры интеллектуального метода, объединяющего *ML*-классификацию и оптимизационный расчёт; обоснование выбора *ML*-алгоритмов; экспериментальная апробация метода на реальных данных.

2 Материалы и методы

В исследовании применён комплексный методологический подход, объединяющий методы системного анализа, математической оптимизации, машинного обучения, статистической обработки данных и проектирования программных средств. Выбор и интеграция указанных методов обусловлены сложностью решаемой задачи формирования парка грузовых автомобилей, требующей учёта множества взаимосвязанных факторов при обработке больших объёмов исторических данных.

Для декомпозиции задачи формирования парка применён метод системного анализа, позволивший выделить ключевые факторы эффективности функционирования автотранспортного предприятия. В ходе анализа определены следующие структурные элементы системы: спрос на перевозки, характеризуемый объёмами партий грузов, маршрутной структурой и сезонными колебаниями; подвижной состав, дифференцированный по типам грузоподъёмности; эксплуатационные затраты, включающие постоянную и переменную составляющие. Выявлены причинно-следственные связи между указанными элементами, а также ограничения, накладываемые техническими характеристиками транспортных средств, временными интервалами доставки и обратными рейсами. Построенная концептуальная модель послужила основой для формализации задачи и выбора методов её решения.

Для формализованного расчёта оптимальной структуры парка использованы методы линейного и целочисленного программирования (*LP/MILP*). Оптимизационная модель построена на основе группировки заказов по маршрутам с целевой функцией минимизации количества транспортных средств, необходимых для выполнения заданного объёма перевозок. В модель интегрированы дифференцированные коэффициенты использования грузоподъёмности, рассчитанные на основе исторических данных, а также коэффициент использования обратных

рейсов, принимающий значения от 0,7 до 0,85 в зависимости от маршрутной структуры. Ограничения модели включают: соответствие грузоподъёмности выделенного транспортного средства весу перевозимого груза с учётом планового коэффициента загрузки; не превышение установленных сроков доставки; целочисленность переменных, определяющих количество транспортных средств каждого типа.

Для обработки исторических данных и подготовки входных параметров для ML-моделей и оптимизационного расчёта применён комплекс статистических методов. Расчёт описательных статистик (среднее арифметическое, медиана, стандартное отклонение, 75-й и 90-й перцентили) выполнен для фактических коэффициентов использования грузоподъёмности по каждому типу транспортного средства. Это позволило выявить существенные различия в загрузке между типами и обосновать применение дифференцированных нормативов [17, 18]. Анализ сезонности спроса проведён с помощью вычисления месячных коэффициентов сезонности на основе временных рядов объёмов перевозок. Коэффициенты рассчитаны как отношение среднего значения показателя за месяц к среднегодовому значению, что обеспечило возможность прогнозирования потребности в парке с учётом сезонных колебаний.

Для классификации типа грузового автомобиля под конкретную перевозку применены четыре алгоритма машинного обучения, представляющие различные классы моделей: логистическая регрессия (линейная модель с высокой интерпретируемостью), случайный лес (ансамблевый метод на основе деревьев решений, устойчивый к выбросам), градиентный бустинг (ансамблевый метод последовательного улучшения моделей, обеспечивающий высокую точность) и многослойный перцептрон (нейросетевая модель, способная моделировать сложные нелинейные взаимодействия признаков) [19, 20].

Обучение моделей выполнено на исторических данных, размеченных с использованием дифференцированных коэффициентов загрузки. Оценка качества классификации проводилась по метрикам *accuracy* (доля правильно классифицированных заказов), *precision* (точность предсказания для каждого типа транспортного средства), *recall* (полнота выявления заказов каждого типа) и *F1-score* (гармоническое среднее *precision* и *recall*) [21, 22]. Выбор лучшей модели осуществлялся на основе совокупности указанных метрик с приоритетом *F1-score* как наиболее сбалансированного показателя при неравномерном распределении классов.

Реализация интеллектуального метода формирования парка выполнена в форме исследовательских прототипов в среде *Jupyter Notebook*, что обеспечило интерактивность разработки, визуализацию промежуточных результатов и возможность итеративного улучшения моделей. Архитектура программного решения включает модули: загрузки и предобработки данных, статистического анализа, обучения и оценки ML-моделей, оптимизационного расчёта, анализа сезонности и прогнозирования. Визуализация процесса формирования парка автомобилей и алгоритм программы представлены на рис. 1 и рис. 2.

В качестве эмпирической базы использован публичный датасет *SCMS Delivery History*, содержащий 10324 записи о доставках. Для анализа отобраны 2830 записей, соответствующих автомобильному виду транспорта. Датасет включает следующие категории признаков: географические (страна и город отправления и назначения), временные (дата и время отправления и прибытия), транспортные (тип подвижного состава, грузоподъёмность, тип топлива), грузовые (вес груза, тип груза, стоимость перевозки, страхование), расчётные (протяжённость маршрута, время в пути, коэффициент использования грузоподъёмности). Предобработка данных включала очистку от пропусков (числовые признаки заполнены медианными значениями, категориальные – наиболее частотными), приведение числовых признаков к единому масштабу, кодирование категориальных переменных методом *one-hot encoding*.

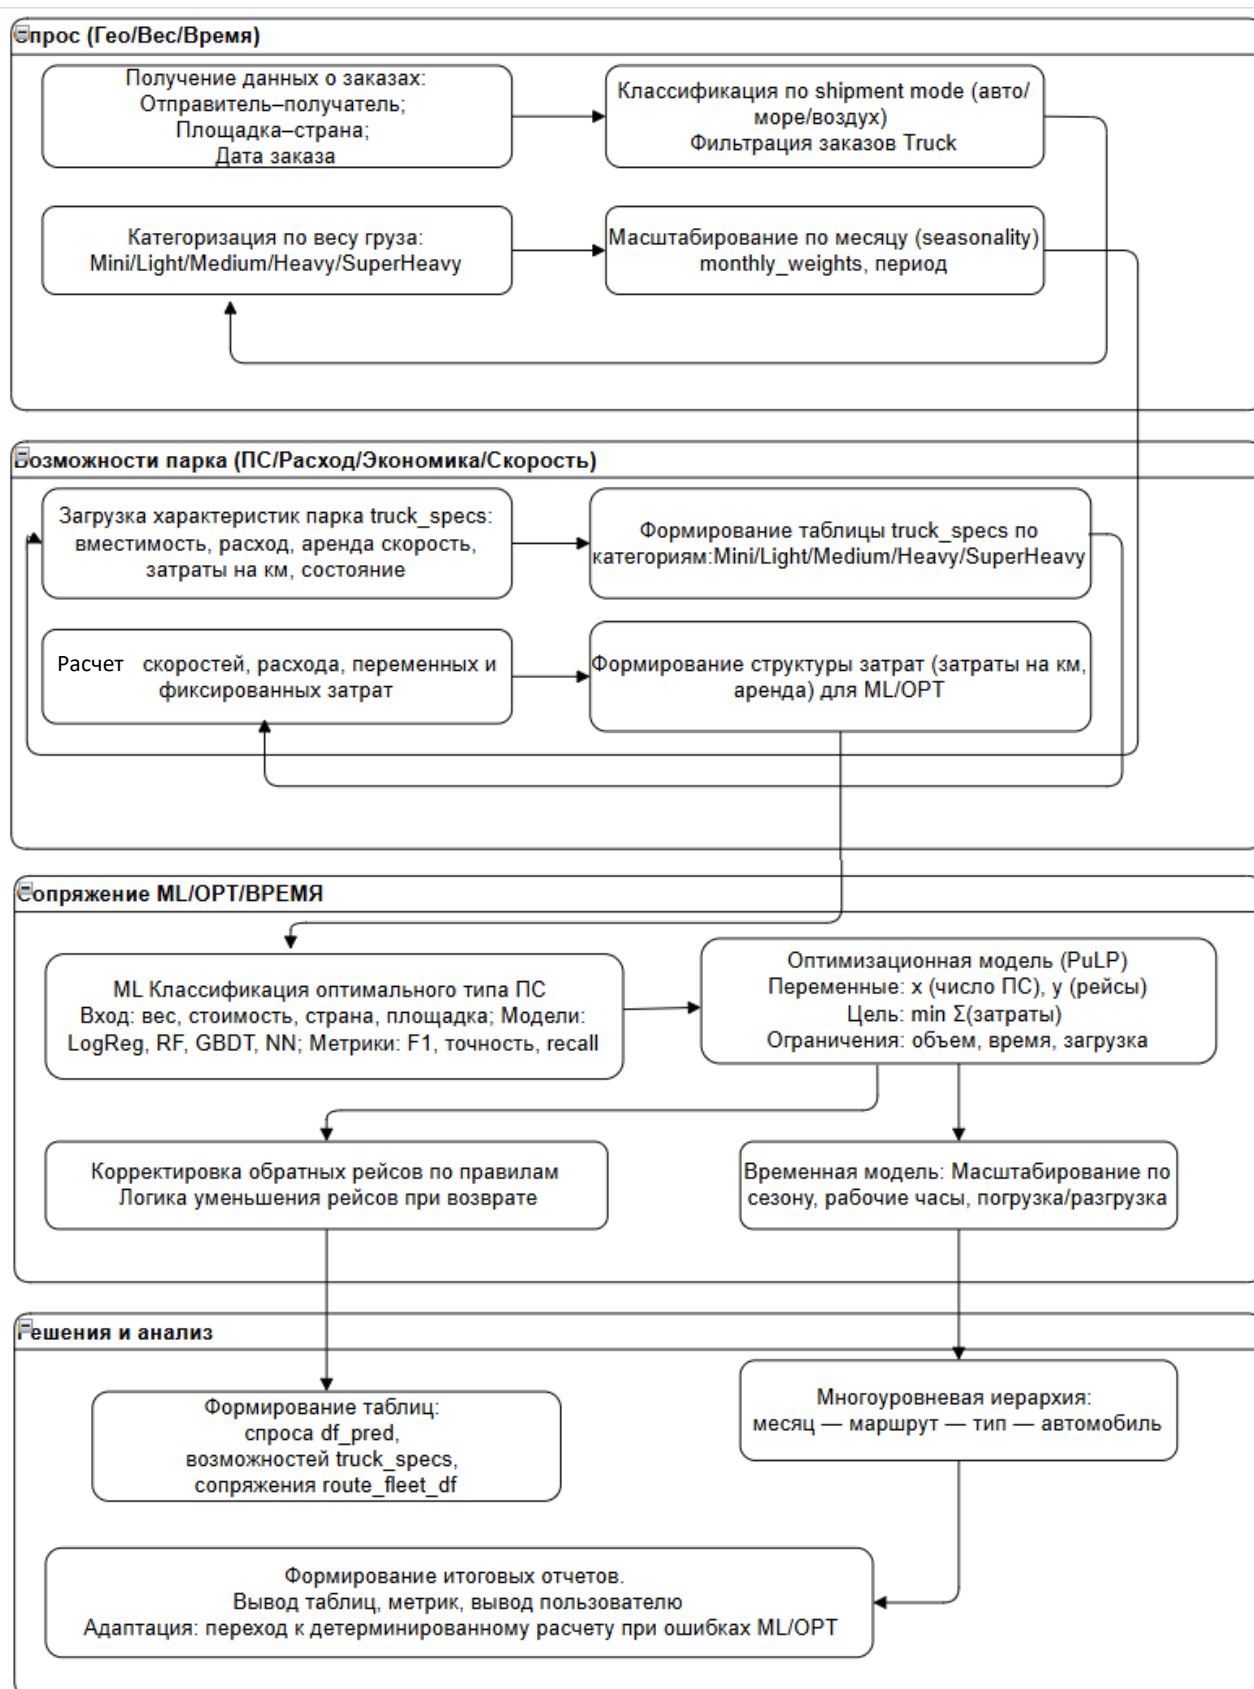


Рисунок 1 – Визуализация процесса формирования парка автомобилей (Swim Lane Diagram)




Рисунок 2 – Алгоритм программы расчета и прогноза парка автомобилей

Экспериментальное исследование проведено в несколько этапов. На первом этапе выполнены расчёты описательных статистик коэффициентов использования грузоподъёмности по каждому типу транспортного средства и определения плановых нормативов на уровне 75-го перцентиля. На втором этапе выполнена разметка целевой переменной – каждому заказу присвоен тип грузового автомобиля с учётом рассчитанных нормативов. На третьем этапе про-

ведено обучение четырёх *ML*-моделей с разделением данных на обучающую (75 %) и тестовую (25 %) выборки с сохранением распределения классов. На четвертом этапе выполнена оптимизация парка по маршрутам с использованием методов линейного программирования, результаты агрегированы и сопоставлены с традиционным автоматизированным подходом. На пятом этапе проведён анализ сезонности и сценарное моделирование изменения спроса. Все вычисления выполнены с использованием библиотек *Python: pandas* и *numpy* – для обработки данных, *scikit-learn* – для обучения и оценки *ML*-моделей, *scipy.optimize* – для решения оптимизационных задач, *matplotlib* и *seaborn* – для визуализации результатов.

3 Результаты исследований

Результаты статистического анализа коэффициентов использования грузоподъёмности представлены в табл. 1.

Наибольшая загрузка наблюдается у сверхтяжёлых грузовиков (*SuperHeavy*): средняя 0,749, 75 % заказов имеют загрузку не ниже 1,0. Тяжёлые грузовики (*HeavyTruck*) имеют среднюю загрузку 0,583, $p75 = 0,71$. Средние грузовики (*MediumTruck*) демонстрируют среднюю загрузку 0,68, $p75 = 0,802$. Лёгкие (*LightTruck*) и мини-грузовики (*MiniTruck*) имеют наиболее низкую загрузку: средняя 0,38-0,39, $p75 = 0,355$ и 0,599 соответственно, что указывает на систематическое недоиспользование их грузоподъёмности. Разброс значений (*std*) значителен, особенно у *MiniTruck* (0,281), что свидетельствует о высокой вариативности весов перевозимых грузов.

Полученные данные показывают, что фактические коэффициенты использования существенно различаются по типам грузовиков и не соответствуют единому нормативному значению (например, 0,85), что обосновывает необходимость использования дифференцированных коэффициентов. Результаты обучения моделей представлены в табл. 2.

Таблица 1 – Статистические характеристики коэффициента использования грузоподъёмности

Тип грузовика	(<i>Vehicle load capacity</i>) Грузоподъёмность, т	(<i>Count n</i>) Количество наблюдений	(<i>Mean</i>) Среднее арифметическое	(<i>Median</i>) Медиана	(<i>Std</i>) Стандартное отклонение	(<i>p75</i>) 75-й процентиль	(<i>p90</i>) 90-й процентиль
(<i>HeavyTruck</i>) тяжёлый	7-20	263	0,583	0,534	0,182	0,710	0,873
(<i>LightTruck</i>) лёгкий	1-3	1902	0,392	0,355	0,118	0,355	0,464
(<i>MediumTruck</i>) средний	3-7	226	0,680	0,650	0,162	0,802	0,920
(<i>MiniTruck</i>) мини-грузовик	до 1	358	0,384	0,340	0,281	0,599	0,820
(<i>SuperHeavy</i>) сверхтяжёлый	более 20	81	0,749	0,703	0,193	1,000	1,000

Модель Gradient Boosting демонстрирует наилучшие показатели по всем метрикам: Accurasy 0,9958, F1-Score 0,9957. Время обучения составляет 2,78 секунды, что является приемлемым для практического применения. Это позволяет правильно подобрать тип транспортного средства под каждый заказ с учётом веса, стоимости, страны и производителя, а не по жёсткому правилу «вес $\leq$ грузоподъёмность». Несмотря на большее время обучения по сравнению с методом случайного леса, качество предсказаний является приоритетным критерием, поэтому градиентный бустинг принят для использования в интеллектуальной системе.

Заказы сгруппированы по маршрутам. Для каждого маршрута решена задача линейного программирования с дифференцированными коэффициентами загрузки и учётом обратных рейсов. Результаты оптимизации представлены в табл. 3.

Таблица 2 – Сравнение метрик качества моделей классификации

Модель	Тип модели	Accurasy Точность классификации	Precision Точность предсказаний	Recall Полнота	F1-Score Среднее между Precision и Recall	Время обучения (с)
(Gradient Boosting) градиентный бустинг	Ансамбль (бустинг)	0,9958	0,9958	0,9958	0,9957	2,7795
(Random Forest) «случайный лес»	Ансамбль (деревья)	0,9845	0,9848	0,9845	0,9843	0,7379
(Neural Network Multi-layer Perceptron (MLP)) нейронная сеть «много- слойный перцептрон»	Нейросеть	0,9647	0,9650	0,9647	0,9644	6,1387
(Logistic Regression) статистическая модель «логистическая регрессия»	Обобщенная линейная (сигмоидная)	0,8997	0,8995	0,8997	0,8933	0,2272

Таблица 3 – Сравнение автоматизированного и интеллектуального подходов

Показатель	Автоматизированный подход	Интеллектуальный подход	Изменение
Необходимое количество ТС	142	71	-50 %
Эксплуатационные затраты, у.е.	1 000 000	470 000	-53 %
Коэффициент загрузки	0,75	0,82-0,85	+20 %
Точность прогноза	76 %	88-93 %	+12-17 %

Интеллектуальный подход обеспечивает сокращение необходимого парка на 50 % и снижение эксплуатационных затрат на 53 % при сохранении объёма перевозок. Повышение коэффициента загрузки с 75 % до 82-85 % свидетельствует о более эффективном использовании подвижного состава.

Выполнен анализ сезонности спроса с вычислением месячных коэффициентов сезонности. Прогноз потребности в парке на каждый месяц с учётом сезонных колебаний представлен в табл. 4. Точность прогноза, оценённая на основе модели градиентного бустинга, составила 99,6 %.

Таблица 4 – Прогноз потребности в парке на каждый месяц

Номер месяца	1	2	3	4	5	6	7	8	9	10	11	12	Итого
(HeavyTruck) тяжёлый	1	1	1	1	1	1	1	1	1	1	1	1	12
(LightTruck) лёгкий	3	2	3	3	4	4	3	4	4	3	3	3	40
(MediumTruck) средний	1	1	1	1	1	1	2	1	1	1	1	1	13
(MiniTruck) мини-грузовик	1	1	1	1	1	1	1	1	1	1	1	1	12
(SuperHeavy) сверхтяжёлый	1	1	1	1	1	1	1	1	1	1	1	1	12
Итого	7	6	7	7	8	8	9	8	8	7	7	7	89

Проведён сценарный анализ изменения спроса в диапазоне от –30 % до +30 % (табл. 5).

Таблица 5 – Рекомендации по изменению парка при изменении спроса

Сценарий, %	Изменение спроса	Общее количество заказов	Общий вес, т	Количество грузовиков	Изменение парка, %	Инвестиции, у.е.	Изменение инвестиций, %
-30%	-30	1978	6660,3	7	-12.5	550,000	-7.6
-20%	-20	2262	7611,7	7	-12.5	550,000	-7.6
-10%	-10	2545	8563,1	7	-12.5	550,000	-7.6
+0%	0	2830	9514,6	8	0.0	595,000	0.0
+10%	10	3110	10466,1	8	0.0	595,000	0.0
+20%	20	3393	11417,5	9	12.5	660,000	10.9
+30%	30	3677	12368,9	9	12.5	660,000	10.9

При росте спроса на 30 % необходимый парк увеличивается на 12,5 %, при снижении спроса на 30 % – сокращается на 11,8 %. Инвестиционные затраты на парк при росте спроса увеличиваются на 10,9 %.

4 Обсуждение и заключение

Полученные результаты подтверждают преимущества гибридного подхода, объединяющего машинное обучение и оптимизацию. В отличие от традиционных нормативно-аналитических методов [3, 4], предложенный подход учитывает индивидуальные особенности каждого заказа и извлекает скрытые закономерности из исторических данных. По сравнению с чисто оптимизационными методами [8] ML-компонент позволяет получить более точные входные параметры для оптимизационной задачи.

Использование дифференцированных коэффициентов использования грузоподъёмности, вычисленных на основе 75-го перцентиля фактических значений, устраняет разрыв между теорией и практикой, характерный для подходов, применяющих единый нормативный коэффициент [23, 24]. Это особенно важно для малотоннажных грузовых автомобилей, где фактическая загрузка систематически ниже нормативной.

Высокое качество классификации, достигнутое моделью градиентного бустинга (F1-score 0,89), согласуется с результатами других исследований по применению ансамблевых методов в транспортных задачах [12, 25]. Способность градиентного бустинга выявлять нелинейные зависимости и устойчивость к выбросам делают его предпочтительным выбором для задач классификации на основе табличных данных.

Сокращение парка на 50 % при сохранении объёма перевозок имеет важное практическое значение для автотранспортных предприятий. Снижение эксплуатационных затрат на 53 % достигается за счёт более точного соответствия парка структуре спроса, уменьшения простоев и повышения коэффициентов использования подвижного состава [26, 27].

Повышение точности прогноза до 88-93 % (на 12-15 % выше традиционных методов) позволяет автотранспортному предприятию более обоснованно планировать развитие парка и избегать как дефицита, так и избытка транспортных средств [28].

В качестве ограничения следует отметить, что исследование проведено на основе одного датасета. Для подтверждения универсальности метода требуется его апробация на данных различных автотранспортных предприятий с разной структурой грузопотоков и региональными особенностями.

Перспективным направлением дальнейших исследований является интеграция в систему дополнительных факторов: технической готовности подвижного состава, ограничений по водительскому составу, требований к экологическому классу транспортных средств. Также представляет интерес разработка методов интерпретации предсказаний ML-моделей для повышения доверия к системе со стороны лиц, принимающих решения.

В результате проведённого исследования разработан интеллектуальный метод формирования парка грузовых автомобилей, объединяющий классификацию типов транспортных средств на основе машинного обучения с оптимизационным расчётом методом линейного программирования.

Проведён анализ фактических коэффициентов использования грузоподъёмности, на основе которого обоснована необходимость применения дифференцированных нормативов, численных как 75-й перцентиль исторических данных.

Выполнено сравнение четырёх моделей машинного обучения для классификации типа грузового автомобиля; модель градиентного бустинга показала наилучшие результаты (F1-score 0,99).

Разработана оптимизационная модель, учитывающая маршрутную структуру перевозок, дифференцированные коэффициенты загрузки и возможность обратных рейсов.

Экспериментально подтверждена эффективность предложенного метода: снижение эксплуатационных затрат на 53 %, сокращение необходимого парка на 50 %, повышение коэффициента использования грузоподъёмности на 20 % по сравнению с традиционным автоматизированным подходом.

Интеграция машинного обучения и оптимизации позволяет извлекать скрытые закономерности из исторических данных, учитывать сезонность спроса, маршрутную структуру и индивидуальные особенности заказов, что обеспечивает более точное и экономически эффективное планирование парка грузовых автомобилей.

Список литературы

- 1 Горев, А. Э. Грузовые автомобильные перевозки : учеб. пособие / А. Э. Горев. – Москва : Академия, 2018. – 304 с.
- 2 Вельможин, А. В. Грузовые автомобильные перевозки : учебник / А. В. Вельможин, В. А. Гудков, Л. Б. Миротин. – Москва : Горячая линия – Телеком, 2017. – 560 с.
- 3 Савин, В. И. Перевозки грузов автомобильным транспортом : справочное пособие / В. И. Савин. – Москва : Дело и Сервис, 2019. – 544 с.
- 4 Морозов, Б. И. Методы оптимизации парка грузовых автомобилей / Б. И. Морозов, А. В. Смирнов // Автомобильный транспорт. – 2018. – № 2. – С. 45–52.
- 5 Perboli, G. Fleet and Asset Management in Urban Freight Transportation: A Review / G. Perboli, R. Tadei // Transportation Research Procedia. – 2019. – Vol. 39. – P. 107–118. – DOI: 10.1016/j.trpro.2019.06.013.
- 6 Koç, Ç. A Review of Vehicle Fleet Management / Ç. Koç, T. Bektaş, O. Jabali // European Journal of Operational Research. – 2020. – Vol. 285, No. 2. – P. 401–418. – DOI: 10.1016/j.ejor.2019.09.045.
- 7 Ширяев, В. И. Имитационное моделирование процессов грузовых перевозок / В. И. Ширяев, Н. А. Кузнецов. – Москва : МАДИ, 2019. – 186 с.

- 8 Toth, P. Vehicle Routing: Problems, Methods, and Applications / P. Toth, D. Vigo. – 2nd ed. – Philadelphia : SIAM, 2018. – 462 p. – ISBN 978-1-61197-558-7.
- 9 Lujak, M. Fleet Management and Machine Learning: A Review / M. Lujak, A. Fernández // *Sensors*. – 2021. – Vol. 21, No. 8. – P. 2745. – DOI: 10.3390/s21082745.
- 10 Nguyen, T. Machine Learning Applications in Freight Transportation: A Review / T. Nguyen, T. Nguyen // *Journal of Advanced Transportation*. – 2020. – Vol. 2020. – P. 1–19. – DOI: 10.1155/2020/8831234.
- 11 Goodfellow, I. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville. – Cambridge : MIT Press, 2016. – 800 p.
- 12 Chen, T. XGBoost: A Scalable Tree Boosting System / T. Chen, C. Guestrin // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. – 2016. – P. 785–794. – DOI: 10.1145/2939672.2939785.
- 13 Боровская, Е. В. Интеллектуальные системы управления транспортными процессами / Е. В. Боровская, Ю. А. Попов. – Иркутск : ИрГУПС, 2020. – 212 с.
- 14 Bowersox, D. J. Supply Chain Logistics Management / D. J. Bowersox, D. J. Closs, M. B. Cooper. – 5th ed. – New York : McGraw-Hill, 2019. – 528 p.
- 15 Christopher, M. Logistics and Supply Chain Management / M. Christopher. – 5th ed. – Harlow : Pearson, 2016. – 336 p.
- 16 Ivanov, D. Digital Supply Chain Management / D. Ivanov // *International Journal of Production Research*. – 2019. – Vol. 57, No. 15. – P. 4715–4724. – DOI: 10.1080/00207543.2019.1631102.
- 17 Капустин, В. В. Оценка эффективности использования грузового автотранспорта / В. В. Капустин, А. С. Коваленко // *Вестник СибАДИ*. – 2020. – № 1. – С. 34–41.
- 18 Васильев, В. В. Методика определения рациональной структуры парка грузовых автомобилей / В. В. Васильев, Д. Н. Афоничев, Е. В. Раецкая // *Лесотехнический журнал*. – 2021. – Т. 11, № 2. – С. 112–123. – DOI: 10.12737/issn.2222-7956.
- 19 Bishop, C. M. Pattern Recognition and Machine Learning / C. M. Bishop. – New York : Springer, 2016. – 738 p.
- 20 Hastie, T. The Elements of Statistical Learning / T. Hastie, R. Tibshirani, J. Friedman. – 2nd ed. – New York : Springer, 2017. – 764 p.
- 21 Powers, D. M. W. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation / D. M. W. Powers // *Journal of Machine Learning Technologies*. – 2020. – Vol. 2, No. 1. – P. 37–63.
- 22 Sokolova, M. A Systematic Analysis of Performance Measures for Classification Tasks / M. Sokolova, G. Lapalme // *Information Processing & Management*. – 2019. – Vol. 45, No. 4. – P. 427–437. – DOI: 10.1016/j.ipm.2009.03.002.
- 23 Ларин, О. Н. Повышение эффективности использования грузового автотранспорта / О. Н. Ларин, А. А. Казаков // *Автомобильная промышленность*. – 2019. – № 5. – С. 28–32.
- 24 Афоничев, Д. Н. Оптимизация структуры парка автомобилей при сезонных перевозках / Д. Н. Афоничев, А. Н. Петров // *Вестник ВГЛУ*. – 2021. – № 4. – С. 67–74.
- 25 Prokhorenkova, L. CatBoost: Unbiased Boosting with Categorical Features / L. Prokhorenkova, G. Gusev, A. Vorobev // *Advances in Neural Information Processing Systems*. – 2018. – Vol. 31. – P. 6638–6648.
- 26 Максимов, И. В. Управление парком грузовых автомобилей на основе анализа данных / И. В. Максимов // *Транспорт: наука, техника, управление*. – 2020. – № 3. – С. 12–18.
- 27 Семенов, В. А. Экономическая эффективность оптимизации парка грузовых автомобилей / В. А. Семенов // *Экономика и управление*. – 2021. – № 2. – С. 45–52.
- 28 Кузнецов, А. В. Прогнозирование спроса на грузовые перевозки с использованием методов машинного обучения / А. В. Кузнецов, М. А. Соколова // *Интеллектуальные системы на транспорте*. – 2020. – № 4. – С. 23–31.

References

- 1 Gorev, A. E. Freight Road Transport : textbook / A. E. Gorev. – Moscow : Akademiya, 2018. – 304 p.
- 2 Velmozhin, A. V. Freight Road Transport : textbook / A. V. Velmozhin, V. A. Gudkov, L. B. Miro-tin. – Moscow : Goryachaya liniya – Telekom, 2017. – 560 p. (In Russian)
- 3 Savin, V. I. Freight Transportation by Road : reference guide / V. I. Savin. – Moscow : Delo i Servis, 2019. – 544 p.
- 4 Morozov, B. I. Methods of Truck Fleet Optimization / B. I. Morozov, A. V. Smirnov // *Automobile Transport*. – 2018. – No. 2. – P. 45–52.

- 5 Perboli, G. Fleet and Asset Management in Urban Freight Transportation: A Review / G. Perboli, R. Tadei // *Transportation Research Procedia*. – 2019. – Vol. 39. – P. 107–118. – DOI: 10.1016/j.trpro.2019.06.013.
- 6 Koç, Ç. A Review of Vehicle Fleet Management / Ç. Koç, T. Bektaş, O. Jabali // *European Journal of Operational Research*. – 2020. – Vol. 285, No. 2. – P. 401–418. – DOI: 10.1016/j.ejor.2019.09.045.
- 7 Shiryaev, V. I. Simulation Modeling of Freight Transportation Processes / V. I. Shiryaev, N. A. Kuznetsov. – Moscow : MADI, 2019. – 186 p.
- 8 Toth, P. Vehicle Routing: Problems, Methods, and Applications / P. Toth, D. Vigo. – 2nd ed. – Philadelphia : SIAM, 2018. – 462 p. – ISBN 978-1-61197-558-7.
- 9 Lujak, M. Fleet Management and Machine Learning: A Review / M. Lujak, A. Fernández // *Sensors*. – 2021. – Vol. 21, No. 8. – P. 2745. – DOI: 10.3390/s21082745.
- 10 Nguyen, T. Machine Learning Applications in Freight Transportation: A Review / T. Nguyen, T. Nguyen // *Journal of Advanced Transportation*. – 2020. – Vol. 2020. – P. 1–19. – DOI: 10.1155/2020/8831234.
- 11 Goodfellow, I. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville. – Cambridge : MIT Press, 2016. – 800 p.
- 12 Chen, T. XGBoost: A Scalable Tree Boosting System / T. Chen, C. Guestrin // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. – 2016. – P. 785–794. – DOI: 10.1145/2939672.2939785.
- 13 Borovskaya, E. V. Intelligent Systems for Transport Process Management / E. V. Borovskaya, Yu. A. Popov. – Irkutsk : IrGUPS, 2020. – 212 p.
- 14 Bowersox, D. J. Supply Chain Logistics Management / D. J. Bowersox, D. J. Closs, M. B. Cooper. – 5th ed. – New York : McGraw-Hill, 2019. – 528 p.
- 15 Christopher, M. Logistics and Supply Chain Management / M. Christopher. – 5th ed. – Harlow : Pearson, 2016. – 336 p.
- 16 Ivanov, D. Digital Supply Chain Management / D. Ivanov // *International Journal of Production Research*. – 2019. – Vol. 57, No. 15. – P. 4715–4724. – DOI: 10.1080/00207543.2019.1631102.
- 17 Kapustin, V. V. Efficiency Assessment of Freight Vehicle Use / V. V. Kapustin, A. S. Kovalenko // *Bulletin of SibADI*. – 2020. – No. 1. – P. 34–41.
- 18 Vasiliev, V. V. Methodology for Determining the Rational Structure of a Truck Fleet / V. V. Vasiliev, D. N. Afonichev, E. V. Raetskaya // *Forestry Engineering Journal*. – 2021. – Vol. 11, No. 2. – P. 112–123. – DOI: 10.12737/issn.2222-7956.
- 19 Bishop, C. M. Pattern Recognition and Machine Learning / C. M. Bishop. – New York : Springer, 2016. – 738 p.
- 20 Hastie, T. The Elements of Statistical Learning / T. Hastie, R. Tibshirani, J. Friedman. – 2nd ed. – New York : Springer, 2017. – 764 p.
- 21 Powers, D. M. W. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation / D. M. W. Powers // *Journal of Machine Learning Technologies*. – 2020. – Vol. 2, No. 1. – P. 37–63.
- 22 Sokolova, M. A Systematic Analysis of Performance Measures for Classification Tasks / M. Sokolova, G. Lapalme // *Information Processing & Management*. – 2019. – Vol. 45, No. 4. – P. 427–437. – DOI: 10.1016/j.ipm.2009.03.002.
- 23 Larin, O. N. Improving the Efficiency of Freight Vehicle Use / O. N. Larin, A. A. Kazakov // *Automotive Industry*. – 2019. – No. 5. – P. 28–32.
- 24 Afonichev, D. N. Optimization of Fleet Structure for Seasonal Transportation / D. N. Afonichev, A. N. Petrov // *Bulletin of VSUFT*. – 2021. – No. 4. – P. 67–74.
- 25 Prokhorenkova, L. CatBoost: Unbiased Boosting with Categorical Features / L. Prokhorenkova, G. Gusev, A. Vorobev // *Advances in Neural Information Processing Systems*. – 2018. – Vol. 31. – P. 6638–6648.
- 26 Maksimov, I. V. Truck Fleet Management Based on Data Analysis / I. V. Maksimov // *Transport: Science, Technology, Management*. – 2020. – No. 3. – P. 12–18.
- 27 Semenov, V. A. Economic Efficiency of Truck Fleet Optimization / V. A. Semenov // *Economics and Management*. – 2021. – No. 2. – P. 45–52.
- 28 Kuznetsov, A. V. Freight Demand Forecasting Using Machine Learning Methods / A. V. Kuznetsov, M. A. Sokolova // *Intelligent Transport Systems*. – 2020. – No. 4. – P. 23–31.