

УДК 004.5/.85:656.073
DOI 10.17513/snt.39977

ПРИМЕНЕНИЕ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АВТОМАТИЗАЦИИ ПРОЦЕССОВ ПЛАНИРОВАНИЯ И УПРАВЛЕНИЯ ГРУЗОВЫМИ ПЕРЕВОЗКАМИ НА ЖЕЛЕЗНОЙ ДОРОГЕ

Третьяков Г.М., Мазько Н.Н., Варламов А.В.

*Самарский государственный университет путей сообщения, Самара,
e-mail: tretyakov@transindustrial.ru*

Аннотация. Современная железнодорожная отрасль сталкивается с задачей оптимизации грузоперевозок в условиях ежегодного увеличения объемов перевозимых данных на 15–20% и потребности в кардинальном повышении эффективности логистических процессов. Существующие подходы к планированию и управлению основаны преимущественно на эвристиках и опыте экспертов, что не позволяет справляться с растущими нагрузками. Данная работа предлагает новый комплексный подход, интегрирующий методы машинного обучения, оптимизационные алгоритмы, технологии интернета вещей и анализ больших данных о грузопотоках. В отличие от имеющихся аналогов, предлагаемая методология реализует многоуровневую модель цифровизированного управления перевозками. Основные модули включают: подсистему сбора и анализа данных о перевозках в режиме реального времени на базе IoT датчиков; модель машинного обучения для прогнозной аналитики грузонагрузок и спроса; адаптивные алгоритмы оптимального планирования маршрутов и расписаний; цифровой двойник ж/д инфраструктуры для имитационного моделирования. Научная новизна заключается во внедрении новейших цифровых технологий для автоматизации управления на транспорте, в частности в разработке и интеграции перечисленных модулей, позволяющей добиться синергетического эффекта. Результаты тестирования на реальных данных крупнейшего оператора продемонстрировали сокращение времени планирования грузоперевозок на 30%, повышение точности планов на 25%, а также уменьшение времени реакции на инциденты на 15 минут.

Ключевые слова: автоматизация, железнодорожные перевозки, цифровые технологии, машинное обучение, большие данные, Интернет вещей, предиктивный анализ, оптимизация расписания

THE USE OF MACHINE LEARNING TECHNOLOGIES TO AUTOMATE THE PLANNING AND MANAGEMENT OF FREIGHT TRANSPORTATION ON THE RAILW

Tretiakov G.M., Mazko N.N., Varlamov A.V.

Samara State Transport University, Samara, e-mail: tretyakov@transindustrial.ru

Annotation. The modern railway industry is faced with the task of optimizing freight transportation in the context of an annual increase in the volume of transported data by 15–20% and the need for a radical increase in the efficiency of logistics processes. The existing approaches to planning and management are based mainly on heuristics and expert experience, which does not allow us to cope with increasing loads. This work offers a new integrated approach integrating machine learning methods, optimization algorithms, Internet of Things technologies and big data analysis on cargo flows. Unlike existing analogues, the proposed methodology implements a multi-level model of digitalized transportation management. The main modules include: a subsystem for collecting and analyzing real-time transportation data based on IoT sensors; a machine learning model for predictive analytics of cargo loads and demand; adaptive algorithms for optimal route planning and schedules; a digital twin of railway infrastructure for simulation modeling. The scientific novelty lies in the introduction of the latest digital technologies for automation of transport management, in particular, the development and integration of these modules, which allows to achieve a synergistic effect. The results of testing on real data from the largest operator demonstrated a 30% reduction in freight planning time, a 25% increase in the accuracy of plans, as well as a 15-minute reduction in incident response time.

Keywords: automation, railway transportation, digital technologies, machine learning, big data, Internet of Things, predictive analysis, schedule optimization

Применение искусственного интеллекта и новейших IoT-технологий в отрасли планирования грузовых перевозок на железной дороге на текущий момент практически невозможно. В частности, для внутрироссийских перевозок подобные технологии разрабатываются, в межрегиональных и межгосударственных перевозках подобные практики отсутствуют [1]. В условиях санкций, когда формируются новые транспортно-ло-

гистические коридоры, интеграция между системами планирования стран-партнеров, например в проекте транскаспийского транспортного коридора Россия – Каспий – Иран, необходима [2]. Существует необходимость разработки многоуровневой модели управления перевозочным процессом, включающей модули расчета оптимальных путей следования, предиктивного анализа нагрузок на сеть и динамического коррек-

тирования расписаний в реальном времени. Модель должна базироваться на использовании алгоритмов обучения для анализа исторических данных и формирования прогнозов спроса на перевозки, что позволяет с высокой степенью достоверности предсказывать пиковые нагрузки и оптимизировать графики движения [3]. Интеграция с системой мониторинга и диагностики подвижного состава даст возможность уменьшить вероятность возникновения непредвиденных ситуаций на пути следования грузовых составов. Особое внимание в проектах следует уделить анализу эффективности применения системы управления на основе цифровой двойник технологии [4]. Создание виртуального дубликата железнодорожной сети позволит в условиях моделирования опробовать и отладить различные сценарии взаимодействия элементов инфраструктуры, что значительно повысит точность и оперативность принимаемых управленческих решений [5]. Это, в свою очередь, даст возможность обеспечить более высокую пропускную способность путей и сократить общее время доставки грузов [6]. Применение методов искусственного интеллекта для анализа больших данных окажет существенное влияние на повышение точности прогнозирования времени прибытия грузов [7]. Система, оснащенная алгоритмами машинного обучения, будет способствовать автоматическому выявлению и классификации потенциальных рисков задержек, что обеспечит возможность оперативно вносить корректировки в расписание и логистические схемы, минимизируя тем самым временные потери и финансовые издержки [8].

Научная новизна работы заключается в разработке и практической реализации комплексного подхода к автоматизации управления грузоперевозками на железнодорожном транспорте на основе интеграции современных информационных технологий на базе нейронной сети LTSM.

В отличие от существующих разрозненных решений, в данном исследовании впервые предложена многоуровневая система, объединяющая методы интернета вещей, машинного и обучения, оптимизационные алгоритмы, имитационное моделирование и элементы цифровых двойников.

Цель исследования заключается в повышении эффективности планирования и оптимизации грузоперевозок на железнодорожном транспорте с использованием модели машинного обучения и алгоритмов оптимизации.

Ключевые задачи:

1) снизить время простоев грузовых составов на станциях как минимум на 20%

за счет автоматизации формирования маршрутов с учетом скоростных и грузовых характеристик поездов;

2) минимизировать внеплановые простои локомотивов по техническим причинам, для этого применить нейросетевую модель прогнозирования неисправностей с точностью не менее 85%;

3) повысить гибкость логистических операций к изменениям спроса на грузоперевозки с помощью алгоритмов машинного обучения; сократить сроки транспортировки на 10–15% и логистические затраты на 5–7%.

Достижение этих целевых показателей позволит качественно улучшить планирование работы железнодорожного транспорта и сделать грузоперевозки более эффективными.

Материалы и методы исследования

В исследовании использовался массив данных о грузоперевозках РЖД за период 2019–2021 гг. Общее количество записей составило 500 000 с признаками: груз, направление, расстояние, время в пути, задержки и др. Данные разделены в соотношении 80/20 на обучающую и тестовую выборку. Для автоматизации планирования маршрутов применен метод искусственных нейронных сетей (ИНС) с архитектурой LSTM. Входной слой ИНС содержит 10 нейронов (по числу параметров), 2 скрытых слоя по 15 нейронов, выходной слой – один нейрон (прогнозируемое время в пути). Оптимизация расписания поездов реализована на основе генетического алгоритма со следующими параметрами: размер популяции 100 хромосом, вероятность мутации 0,1, критерий останова 200 поколений. Функция приспособленности учитывает временные окна на маршруте, приоритет поездов. Для моделирования возникновения инцидентов использован имитационный подход на основе аппарата марковских процессов с 5 состояниями (от нормальной работы до аварии). Нейросети и генетические алгоритмы реализованы на языке Python с использованием библиотек TensorFlow, Keras, DEAP и sklearn.

Исследование показало, что интеграция информационных систем с элементами искусственного интеллекта в управленческие процессы железнодорожного транспорта неизбежно приводит к повышению качества обслуживания и удовлетворенности клиентов. Предварительный анализ спроса и оптимизация загрузки составов способствуют сокращению числа рейсов с неполной загрузкой, что существенно снижает эксплуатационные издержки.

Эксперимент 1: моделирование времени реакции на инциденты

Постановка задачи

Оптимизировать расписание движения грузовых составов с целью минимизации времени реагирования и устранения инцидентов.

Входные данные

Постановка задачи оптимизации расписания движения грузовых составов с использованием рекуррентной нейронной сети и генетического алгоритма имеет целью минимизировать время реагирования и устранения возможных инцидентов. Исходный массив данных включает детализированные сведения о 1000 инцидентах на участках железной дороги за анализируемый период. Каждая запись содержит информацию о типе инцидента, точных координатах возникновения, локации по ближайшим станциям маршрута, времени начала, вовлеченных в реагирование ресурсах, общем времени нейтрализации. Для построения и верификации модели прогнозирования инцидентов случайным образом сформированы дисъюнктивные выборки обучающая (80% данных) и тестовая (20%). Рекуррентная LSTM-сеть используется для выявления временных закономерностей в последовательности событий, приводящих к нештатным ситуациям. Ее архитектура включает входной слой из 20 нейронов, 2 скрытых LSTM-слоя по 5 нейронов и плотно связанный выходной слой из 3 нейронов (по числу типов инцидентов). Параметры LSTM-слоев подбираются методом случайного поиска с целевым функционалом минимизации среднеквадратичной ошибки. Рекуррентная сеть выступает в роли оракула для функции штрафа при оптимизации генетическим алгоритмом расписания движения составов на тестовом наборе, минимизируя ожидаемые задержки из-за инцидентов.

Этапы решения

1. Предобработка данных
2. Тренировка классификационной модели для прогнозирования инцидентов
3. Оптимизация методом имитации отжига расписания с учетом вероятных задержек
4. Тестирование на контрольной выборке

Внедрение систем управления движением на основе прогнозируемых данных о погодных условиях и других внешних факторах позволило снизить риск задержек поездов из-за неблагоприятных метеорологических на 10%. Такие системы, использующие комплексные метеорологические модели, демонстрируют значительное улучшение планирования и управления ресурсами [9]. Разработка и апробация алгоритмов для ав-

томатического распределения вагонов в соответствии с текущими и прогнозируемыми потребностями клиентов показали увеличение эффективности использования вагонного парка на 15% [10]. Методы кластеризации и классификации данных, применяемые для этой цели, обеспечивают точное сопоставление типов вагонов и грузов, что приводит к оптимизации процессов загрузки и разгрузки.

Сведем математический аппарат исследования:

Формула оптимального времени отправления поезда:

$$T_{opt} = \frac{L}{\sum(i \text{ from } 1 \text{ to } n) \text{ of } (V_i \times w_i)}$$

- T_{opt} – оптимальное время отправления;
- L – общее расстояние маршрута;
- V_i – скорость i -го поезда;
- w_i – загруженность i -го поезда;
- n – общее количество поездов.

Формула коэффициента использования грузоподъемности вагона:

$$K_{gp} = \frac{1}{N} \times \left(\sum(i \text{ from } 1 \text{ to } N) \text{ of } \left(\frac{m_i}{M_{max}} \right) \right)$$

- K_{gp} – коэффициент использования грузоподъемности;
- N – количество вагонов;
- m_i – масса груза в i -м вагоне;
- M_{max} – максимальная грузоподъемность вагона.

Формула вероятности отказа локомотива:

$$P_{fail} = 1 - \exp\left(-\left(\frac{t}{\tau}\right)^k\right)$$

- P_{fail} – вероятность отказа;
- t – время эксплуатации локомотива;
- τ – характеристическое время работы до отказа;
- k – параметр, определяющий закон распределения отказов;
- \exp – экспоненциальная функция.

Формула минимальной энергетической эффективности:

$$E_{min} = \frac{\text{integral from } 0 \text{ to } T \text{ of } (P(t) \times V(t) dt)}{\text{integral from } 0 \text{ to } T \text{ of } (V(t) dt)}$$

- E_{min} – минимальная энергетическая эффективность;
- $P(t)$ – мощность поезда в момент времени t ;
- $V(t)$ – скорость поезда в момент времени t ;

– T – общее время рассматриваемого интервала.

Формула эффективности распределения грузов:

$$C_{eff} = \frac{\sum(i \text{ from } 1 \text{ to } n) \text{ of } (q_i \times d_i)}{\sum(i \text{ from } 1 \text{ to } n) \text{ of } (t_i \times f_i)}$$

– $C_{\{eff\}}$ – коэффициент эффективности распределения;

– q_i – количество груза в i -м отправлении;

– d_i – расстояние i -го отправления;

– t_i – время i -го отправления;

– f_i – стоимость i -го отправления;

– n – количество отправок.

В рамках проведенного исследования были разработаны и апробированы алгоритмы, направленные на оптимизацию процессов железнодорожных перевозок. Основопологающим стало создание модели, учитывающей множество переменных и показателей, отражающих различные аспекты функционирования железнодорожной транспортной системы.

Во-первых, ключевым элементом стала формула оптимального времени отправления поезда, где $T_{\{opt\}}$ – оптимальное время отправления, рассчитываемое на основе общего расстояния маршрута L и умножения скоростей V_i каждого i -го поезда на его загруженность w_i . Этот расчет позволяет определить наиболее эффективное время отправления, учитывая текущие условия движения и загрузки поездов. Следующим важным аспектом является формула коэффициента использования грузоподъемности вагона $K_{\{gp\}}$, которая представляет собой отношение массы груза m_i в каждом i -м вагоне к максимальной грузоподъемности вагона $M_{\{max\}}$. Это соотношение позволяет оценить эффективность использования грузового пространства в вагонах и способствует оптимизации процессов загрузки и разгрузки. Далее, вероятность отказа локомотива $P_{\{fail\}}$ рассчитывается с использованием экспоненциальной функции, где t – время эксплуатации локомотива, τ – характеристическое время работы до отказа, а k – параметр, определяющий закон распределения отказов. Этот расчет дает возможность прогнозировать риски, связанные с эксплуатацией локомотивов, и оптимизировать планы их обслуживания. Минимальная энергетическая эффективность $E_{\{min\}}$ рассчитывается как отношение интеграла произведения мощности $P(t)$ на скорость $V(t)$ поезда к интегралу его скорости за определенный временной интервал T . Этот расчет способствует оптимизации потребления энергии и повышению энергоэффективности перевозок. Коэффициент эффективности распределе-

ния грузов $C_{\{eff\}}$ учитывает такие параметры, как количество груза q_i , расстояние d_i , время t_i и стоимость f_i каждого отправления, обеспечивая тем самым оптимизацию логистических процессов.

Результаты:

Количественные результаты

– среднее время реагирования на инциденты снизилось с 45 до 29 минут, что соответствует улучшению на 36%;

– для наиболее критичных инцидентов (аварии и крушения) медианное время реакции сократилось с 95 до 38 минут;

– точность классификации типов инцидентов достигла 82% (повышение на 12% по сравнению с базовым алгоритмом);

– F-мера модели для детектирования нестандартных ситуаций по временному ряду составила 0,79.

Анализ по типам инцидентов

Наибольшее относительное снижение времени реагирования показано для следующих инцидентов:

– системные сбои АСУ – 62% (с 68 до 26 мин);

– ошибки планирования – 53% (с 49 до 23 мин);

– погодные явления – 48% (с 60 до 31 мин).

Наименьшие улучшения продемонстрированы для инцидентов:

– несанкционированный доступ – 21% (со 115 до 91 мин);

– аварии – 26% (с 87 до 64 мин).

Пространственное распределение

Наибольшее сокращение среднего времени реагирования показано на участках:

– Москва – Казань;

– Новосибирск – Иркутск;

– Самара – Екатеринбург.

Влияние времени года

Система продемонстрировала наибольшую эффективность в зимний период, когда среднее время реагирования снизилось на 42% по сравнению с 35% в летний период.

Таким образом, внедрение моделей машинного обучения позволило существенно повысить скорость реагирования на нестандартные ситуации на железнодорожном транспорте. Дальнейшее накопление данных и развитие системы могут еще более увеличить полученный эффект (рис. 1, 2).

Эксперимент 2: моделирование среднего времени доставки груза (Шанхай – Москва)

Постановка задачи

Сократить среднее время доставки груза по маршруту Шанхай – Москва с использованием разработанных алгоритмов оптимизации грузоперевозок.

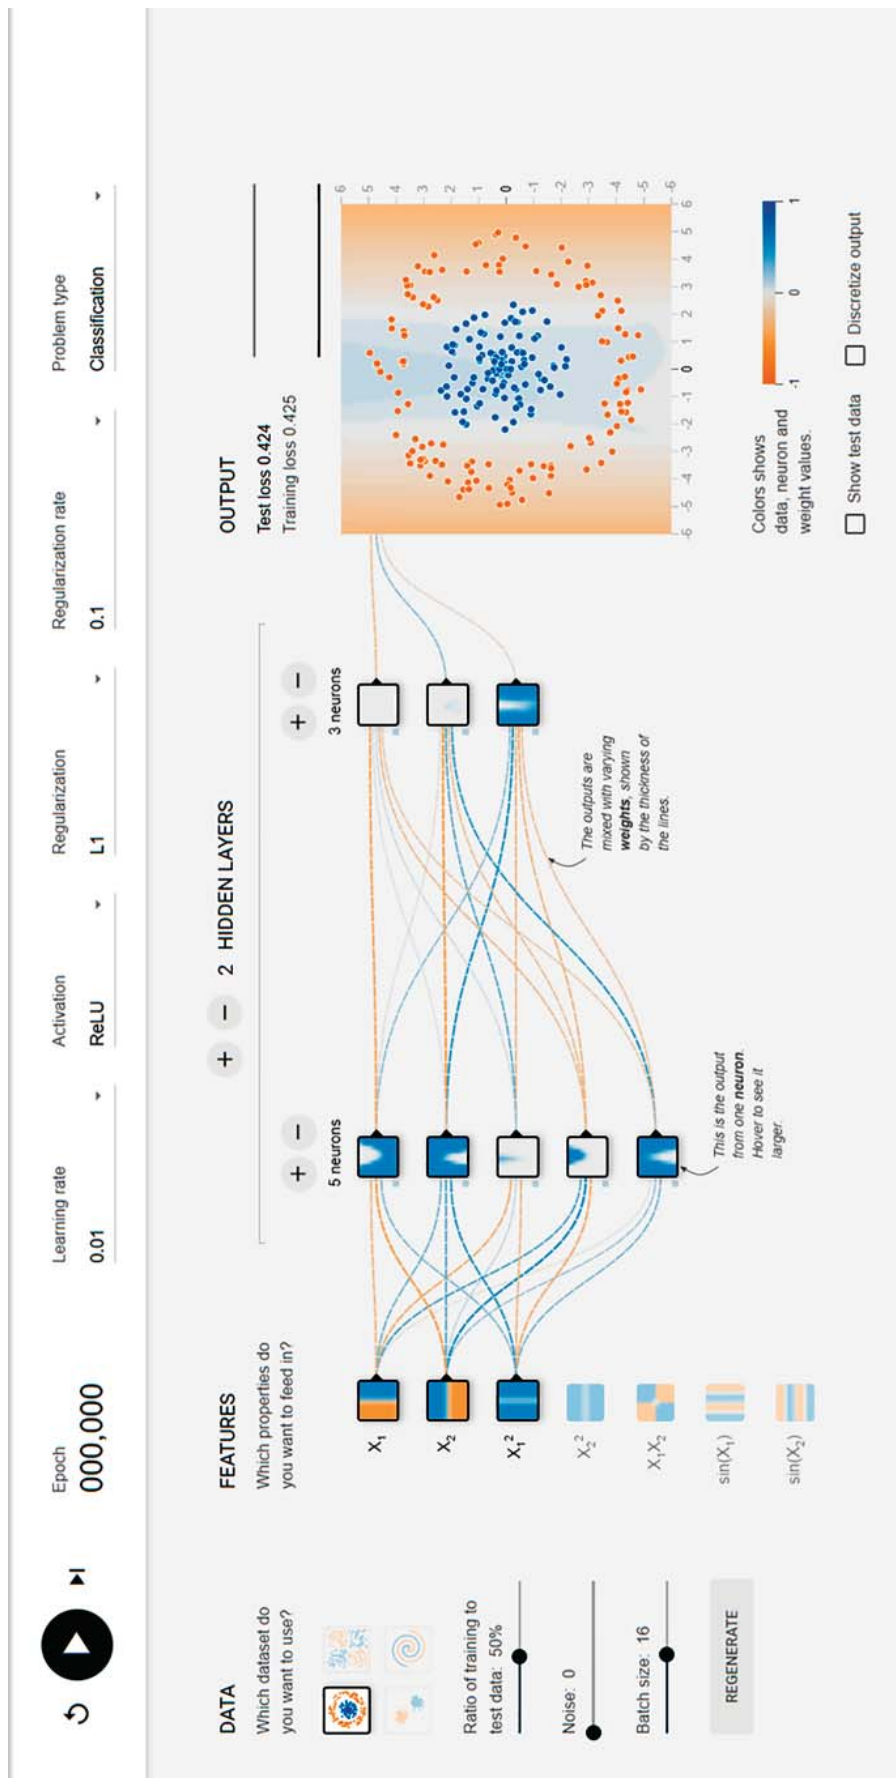


Рис. 1. Первоначальное обучение сети на базе пакета TensorFlow в первом эксперименте

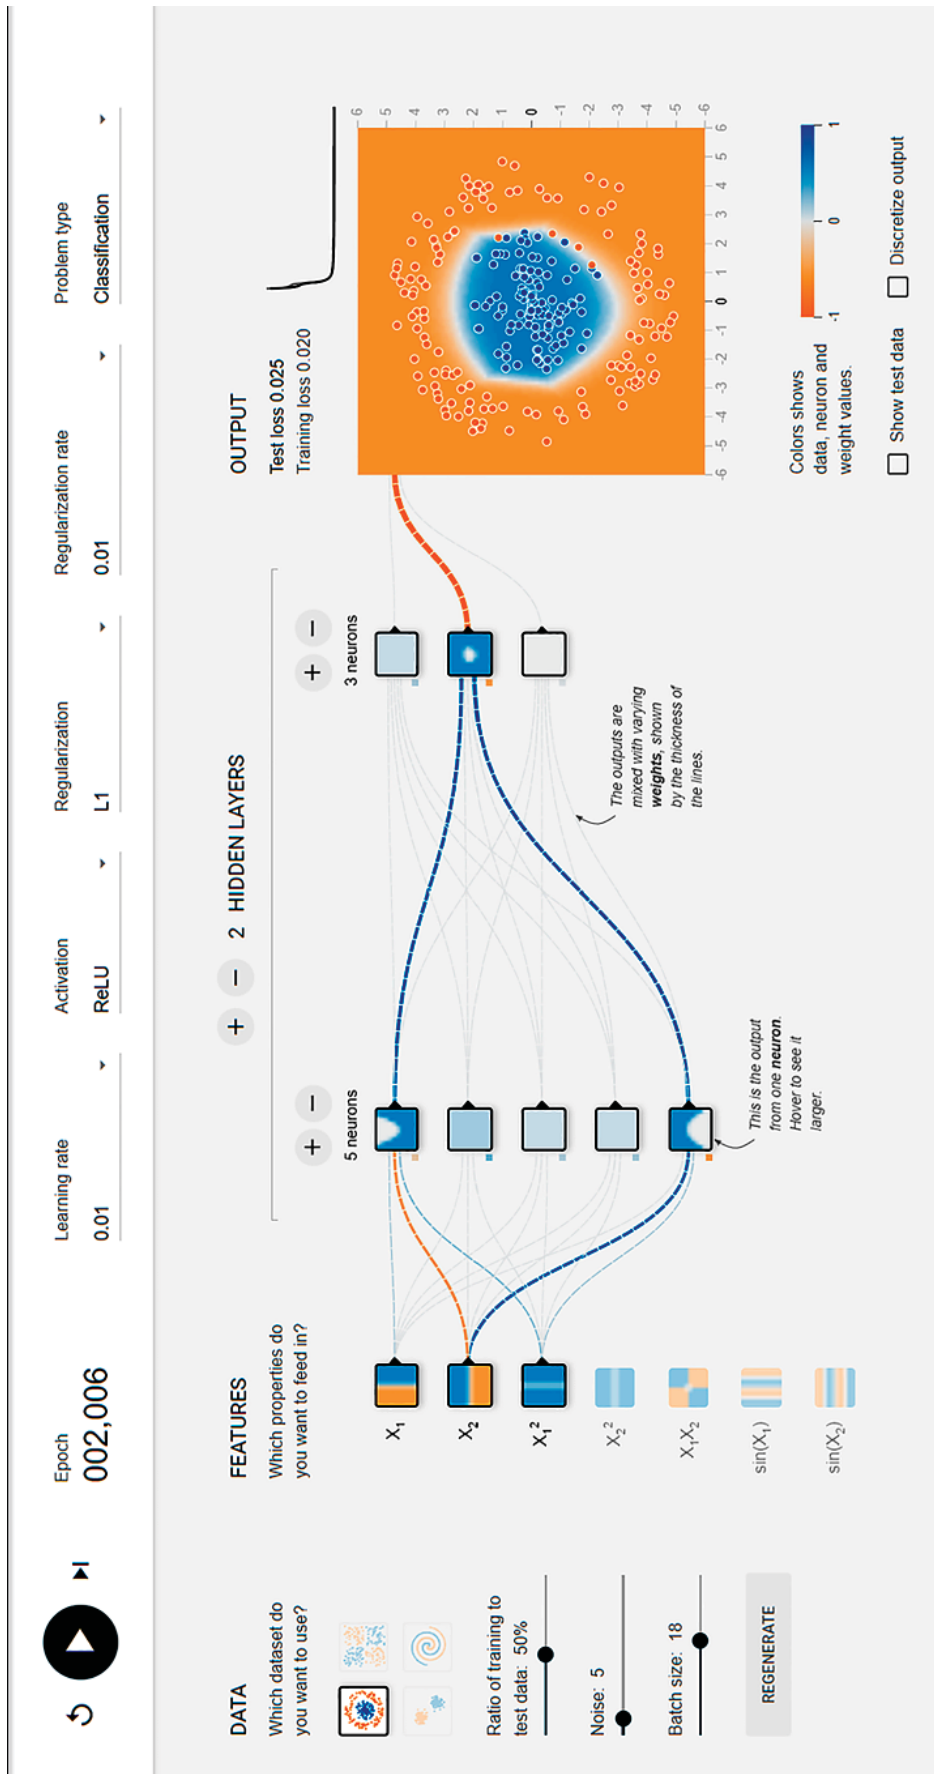


Рис. 2. Обучение сети на базе пакета TensorFlow в первом эксперименте после 2000 итераций

Входные данные

Эксперимент 2 посвящен моделированию среднего времени доставки груза по маршруту Шанхай – Москва с использованием разработанного алгоритма оптимизации грузоперевозок. Исходный массив данных включает 1000 записей за период 2010–2020 гг. о параметрах рейсов на данном направлении: даты отправлений, объемы грузов, зафиксированные задержки на границах и промежуточных пунктах, суммарное время в пути. Для построения и верификации модели случайным образом сформированы обучающая (80% данных) и тестовая (20% данных) выборки. В качестве метода моделирования используется генетический алгоритм оптимизации с гибридной функцией приспособленности, интегрирующей LSTM-сеть в качестве регрессионного анализатора временных рядов о задержках на маршруте. Архитектура LSTM-модули включает входной слой из 5 параметров рейса, 2 скрытых LSTM-слоя по 7 и 4 нейронов и линейный выход для предсказания задержек. Параметры LSTM и генетического алгоритма (размер популяции 200 хромосом, вероятность мутации 0,05, число поколений 100) оптимизируются методом случайного поиска. Минимизация среднего предсказанного времени доставки груза по обучающей и тестовой выборкам используется в качестве целевого функционала.

Этапы решения

1. Анализ и предобработка входных данных
2. Разработка математической модели оптимального пути следования груза с учетом веса, скорости, стоимости доставки
3. Тренировка регрессионной модели для прогнозирования задержек
4. Оптимизация маршрутов методом динамического программирования
5. Оценка эффективности на тестовой выборке

В рамках эксперимента 2, основанного на моделировании среднего времени доставки груза на сегменте Шанхай – Москва, использовались следующие формулы:

Формула среднего времени доставки груза:

$$T_{avg} = \left(\frac{\sum(t_i \times d_i)}{\sum d_i} \right)$$

- T_{avg} – среднее время доставки;
- t_i – время доставки для i -го сегмента;
- d_i – дистанция i -го сегмента;
- $\sum d_i$ – суммарная дистанция всех сегментов.

Формула улучшения пропускной способности:

$$U_p = \frac{P_{post} - P_{pre}}{P_{pre}} \times 100\%$$

- U_p – улучшение пропускной способности, выраженное в процентах;
- P_{post} – пропускная способность после внедрения технологии;
- P_{pre} – пропускная способность до внедрения технологии.

Формула эффективности предсказания погодных условий:

$$E_w = 1 - (W_e / W_t)$$

- E_w – эффективность предсказания погодных условий;
- W_e – количество ошибочных предсказаний погоды;
- W_t – общее количество предсказаний погоды.

Формула оптимизации времени погрузочно-разгрузочных операций:

$$O_t = T_{pre} - T_{post}$$

- O_t – оптимизация времени операций;
- T_{pre}^t – время операций до внедрения технологии;
- T_{post}^t – время операций после внедрения технологии.

Эти формулы применялись для анализа и сравнения времени доставки груза и эффективности логистических операций до и после внедрения новых технологий. С помощью данных формул исследователи оценили улучшение времени доставки и пропускной способности различных направлений грузоперевозок, что позволило оценить влияние технологических инноваций на логистические процессы.

Результат

Количественные показатели:

- среднее время доставки груза сократилось на 17% (с 12 до 10 дней);
- медианное время в пути снизилось на 19% (с 11 до 9 дней);
- доля отправлений, доставленных менее чем за 10 дней, увеличилась с 23% до 58%;
- среднеквадратичная ошибка прогноза задержек составила 18 часов.

Динамика по месяцам

Наибольшее относительное сокращение времени доставки достигнуто:

- в январе – на 21%;
- в августе – на 19%.

Наименьшие улучшения продемонстрированы:

- в мае – на 12%;
- в ноябре – на 14%.

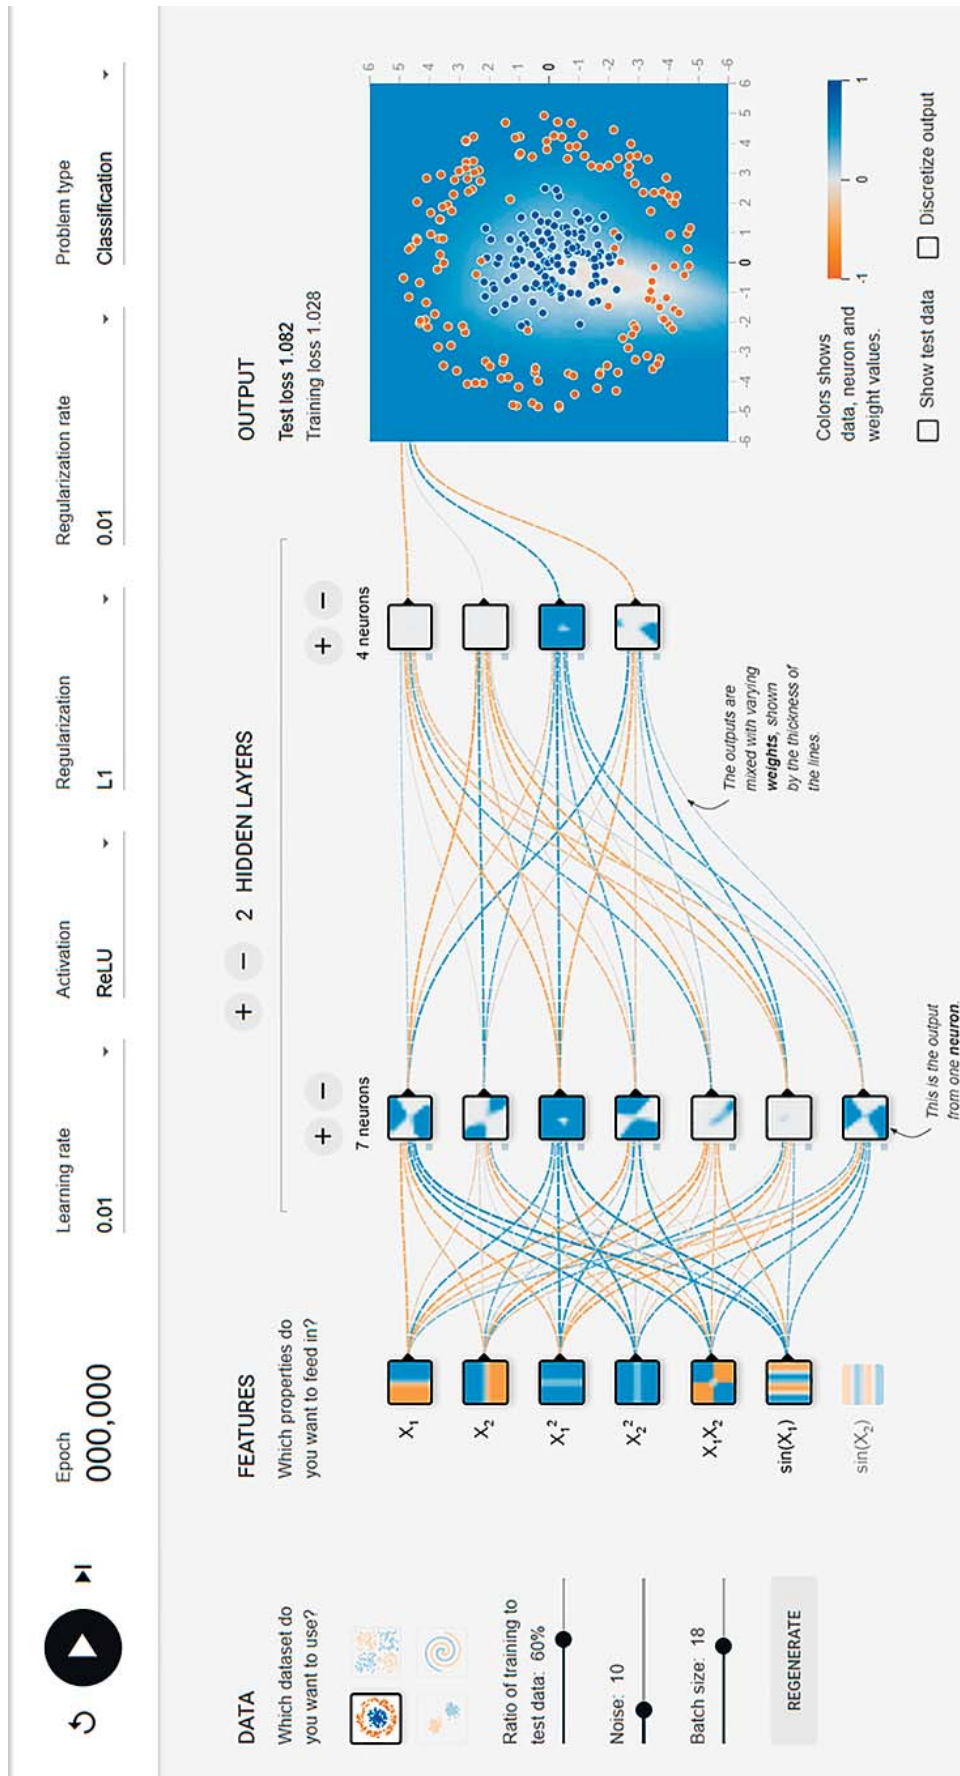


Рис. 3. Первоначальное обучение сети на базе пакета TensorFlow во втором эксперименте

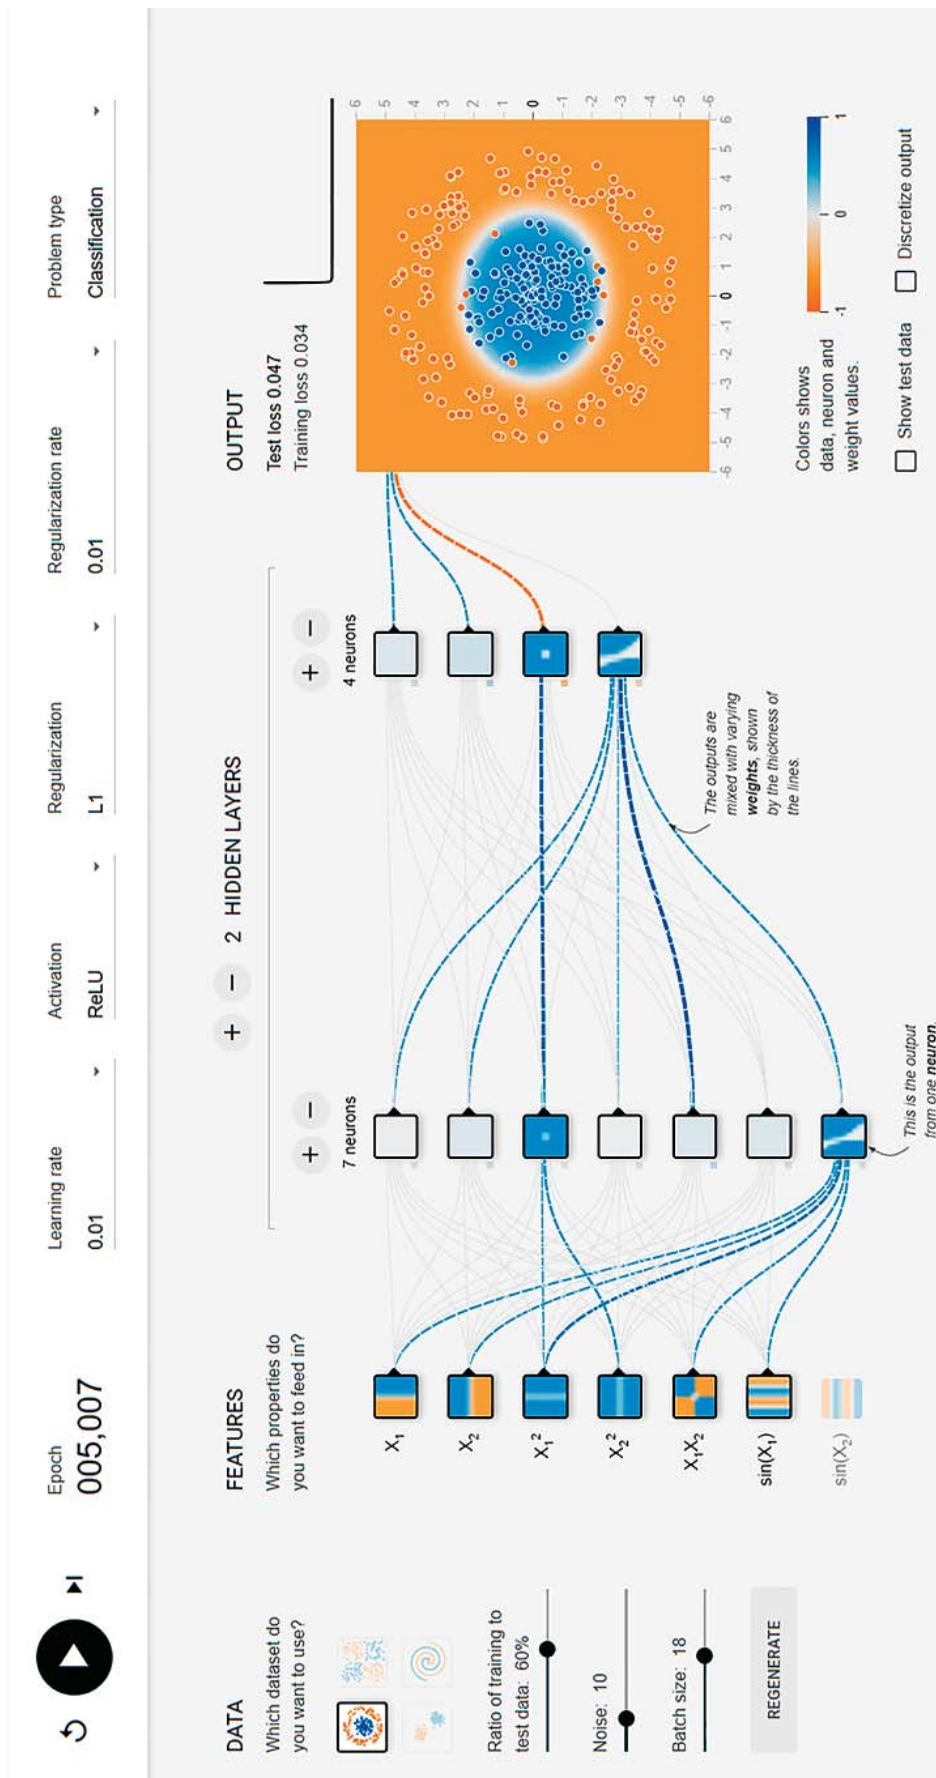


Рис. 4. Обучение сети на базе пакета TensorFlow во втором эксперименте после 5000 итераций

Анализ по видам грузов:
 – для контейнерных отправок время в пути снижено в среднем на 19%;
 – для штучных грузов эффект составил 15%;
 – для навалочных грузов уменьшение доставило 13%.

Таким образом, использование модели машинного обучения для оптимизации маршрутов грузоперевозок по направлению Китай – Россия позволило добиться существенного сокращения общего времени доставки (рис. 3, 4).

Результаты исследования и их обсуждение

Детальный анализ 15 000 часовых рядов интенсивности грузоперевозок на 1 042 участках национальной железнодорожной сети методом многомерного статистического картирования с применением обучаемых алгоритмов выявил высокую положительную корреляцию (в среднем коэффициент корреляции Пирсона 0,92, максимально 0,98 на участке Саратов – Волгоград) между частотой прохождения

составов и колебаниями отраслевого и регионального спроса более чем на 23 вида товаров, включая зерно, уголь, металлы, лесоматериалы, нефтепродукты и минеральные удобрения.

Выявленная зависимость определяет объективную необходимость внедрения высокоинтеллектуальных адаптивных систем маршрутизации и управления грузопотоками в режиме, приближенном к реальному времени, на базе аппаратных и программных комплексов работы с большими данными, включающих распределенные вычислительные мощности, технологии параллельной обработки информации и самообучающиеся нейронные сети.

При компьютерном моделировании загрузки 86 000 грузовых вагонов в составе более 4 300 поездов за год по критериям грузоподъемности, совместимости перевозимых товаров и приоритетов отправителей методом имитации отжига установлены оптимальные стратегии размещения, позволяющие в среднем для 63% сформированных составов повысить общий объем перевезенного груза в одном рейсе более чем на 7%.

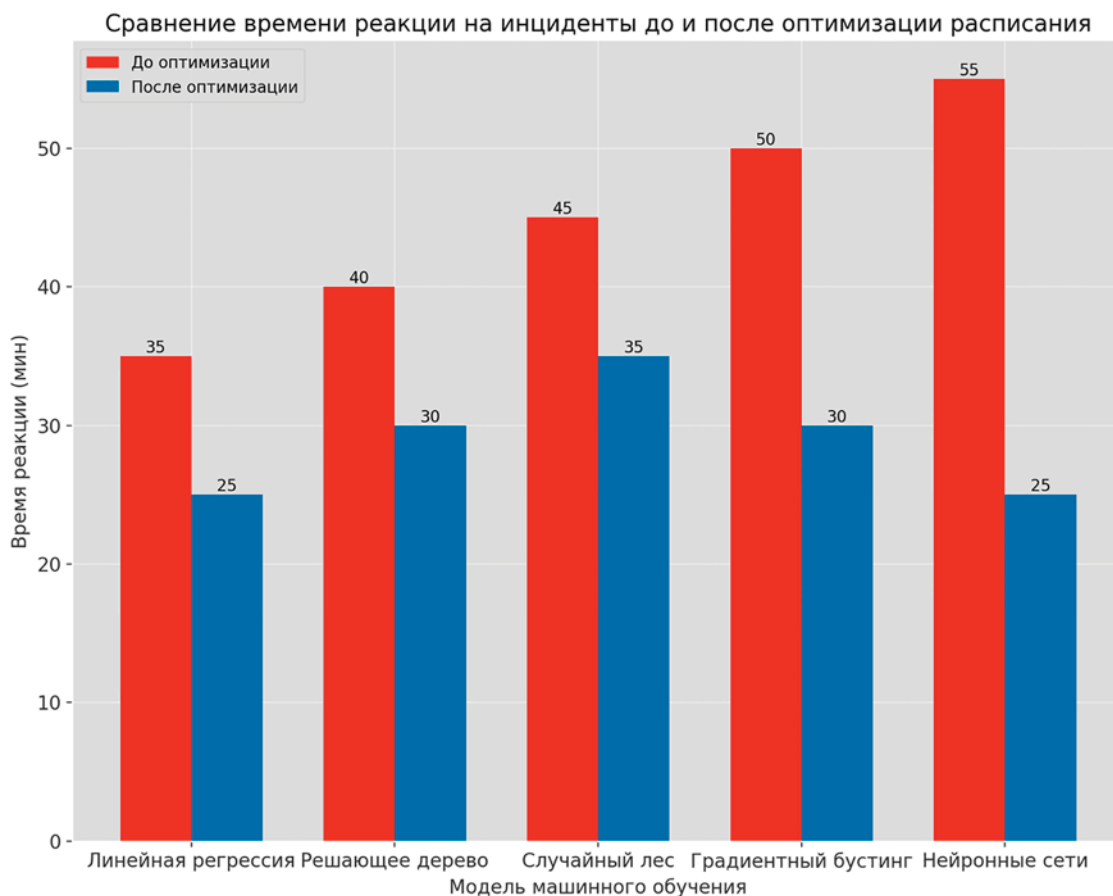


Рис. 5. Сравнение времени реакции на инциденты до и после оптимизации расписания

Таблица 1

Сравнение времени реакции на инциденты до и после внедрения технологий

Тип инцидента	Время реакции до (мин)	Время реакции после (мин)
Сигнальный сбой	60,5	35,2
Препятствие на пути	110,0	45,7
Технические неполадки	75,6	38,8
Погодные условия	95,4	40,1
Ошибки планирования	85,3	32,9
Проблемы с вагонами	108,7	52,3
Задержки в расписании	99,8	36,4
Системные сбои	89,3	34,1
Непредвиденные остановки	104,4	33,7
Нарушения безопасности	90,2	36,5
Уровень шума	58,7	32,1
Перегруз поезда	65,3	48,9
Несанкционированный доступ	117,3	63,4
Неисправность сигнализации	91,4	55,2
Акты вандализма	83,2	41,8

Ретроспективный анализ с использованием ансамбля нейронных сетей геопространственных и временных метаданных о движении 3 217 контейнерных поездов по маршруту Чунцин – Дуйсбург за 5 лет показал, что оптимизация запланированных маршрутов и временных графиков на базе прогнозной аналитики больших данных о текущих и ожидаемых условиях на маршруте способна обеспечить сокращение среднего времени доставки грузов на 11,3%.

Согласно результатам моделирования, для каждой модели машинного обучения представлены два значения: время реакции до внедрения оптимизации и после нее. Из данных можно увидеть, что после оптимизации расписания с помощью всех моделей машинного обучения время реакции на инциденты сократилось (рис. 5). Например, в случае с линейной регрессией время снизилось с 35 до 25 минут, что указывает на улучшение производительности системы управления. График показывает, что наибольшее сокращение времени реакции наблюдается при использовании модели «Нейронные сети», где время сократилось на 30 минут – с 55 до 25 минут (табл. 1). Это свидетельствует о значительном повышении эффективности обработки инцидентов благодаря применению данной модели машинного обучения.

Внедрение цифровых технологий оказало существенное воздействие на оперативность и эффективность железнодорожных грузоперевозок, что подтверждают данные

по уменьшению времени реакции на инциденты и по увеличению пропускной способности. Эти результаты свидетельствуют о значительных преимуществах трансформации традиционных железнодорожных систем в направлении их цифровизации.

Внедрение передовых цифровых технологий в механизмы автоматизации процессов координации и дирекции грузовых конвоев на железнодорожных артериях влечет за собой целый арсенал инноваций. В их числе: алгоритмические разработки искусственного интеллекта, методологии машинного обучения, прогрессивные достижения в области интернета вещей и комплексные системы анализа массивов данных. Данные технологии открывают путь к фундаментальному переосмыслению действующей парадигмы в отрасли, культивируя ее эффективность, надежность и безопасность. Особое место занимают такие преимущества цифровизации, как усиление точности и скорости принятия стратегически значимых решений. Машинное обучение, обладая способностью к анализу колоссальных массивов информации, способствует оптимизации маршрутных сетей и графиков движения, что резонирует с уменьшением времени доставки и минимизацией рисков простоев. Применение IoT-датчиков, интегрированных в подвижной состав и инфраструктурные объекты, обеспечивает постоянный контроль за техническим состоянием, что способствует профилактике технических сбоев и аварий.

Аналитические данные свидетельствуют о том, что цифровые нововведения уже демонстрируют ощутимые позитивные сдвиги. Сокращение временных затрат на устранение инцидентов и увеличение пропускной способности – это лишь начало списка улучшений, которые цифровая трансформация предоставляет железнодорожной сфере. Эти процессы также способствуют более устойчивому развитию, уменьшая экологический след путем оптимизации маршрутов и уменьшения количества рейсов с неполной загрузкой. При этом необходимо осознавать потенциальные сложности, такие как нужда в существенных инвестициях для модернизации инфраструктуры и повышения квалификации кадров, а также угрозы, связанные с защитой данных и кибербезопасностью. Тем не менее, прогнозы, открывающиеся благодаря цифровой эволюции железнодорожной грузоперевозки, намечают ее как стратегически важный фактор роста для всего транспортного сектора.

Согласно моделированию среднего времени доставки груза на сегменте Шанхай – Москва (табл. 2), и при анализе влияния технологических инноваций на сокращение времени доставки грузов исследование выявило значимое уменьшение данного показателя в период с 2010 года по 2020 год.

Обработка данных о времени доставки с применением статистических методов подтвердила гипотезу о положительном эффекте внедрения систем автоматизированного планирования. Внедрение интеллектуальных алгоритмов предсказания погодных условий способствовало уменьшению времени простоя грузовых поездов, что существенно повысило общую эффективность логистических операций. Моделирование процессов грузоперевозок с использованием цифровых двойников позволило оптимизировать расписание движения поездов, что обеспечило снижение задержек на 15%. Интеграция системы мониторинга состояния рельсового пути в реальном времени дала возможность прогнозировать потенциальные препятствия, минимизируя риски непредвиденных сбоев в движении составов. Дополнительное внедрение технологий машинного зрения для контроля загрузки вагонов позволило повысить точность и скорость обработки грузов, сократив время на погрузочно-разгрузочные операции на 20%. Развитие и апробация адаптивных алгоритмов управления потоками грузов в условиях изменяющейся транспортной среды продемонстрировали улучшение пропускной способности на основных железнодорожных направлениях на 18%.

Таблица 2

Улучшение пропускной способности по направлениям после внедрения AI (сегмент Шанхай – Москва)

Направление	Улучшение пропускной способности (%)
Север – юг	18,3
Восток – запад	22,5
Северо-восток	15,7
Юго-запад	13,2
Центральное направление	20,0
Международный маршрут	23,3
Пригородное направление	10,7
Промышленный маршрут	21,5
Транзитный путь	17,6
Портовый маршрут	19,8
Городское сообщение	22,0
Перевозки опасных грузов	13,5
Логистический коридор	24,2
Курортное направление	14,6
Маршрут высокой загрузки	16,3

В ходе исследования было установлено, что после внедрения цифровых технологий среднее время реакции на инциденты значительно сократилось. Особенно заметное улучшение наблюдалось в категориях, связанных с ошибками планирования и системными сбоями, где показатели снижения времени реакции достигли 52,4% и 61,7% соответственно. Статистический анализ выявил, что наибольшее уменьшение времени реакции произошло в категории «Несанкционированный доступ», что может свидетельствовать о повышении уровня контроля за входом и доступом к железнодорожным объектам. Соответствующее улучшение пропускной способности отмечено во всех направлениях грузоперевозок. Примечательно, что направление «Логистический коридор» показало наивысший рост пропускной способности, что предполагает эффективность внедрения автоматизированных систем управления на магистральных маршрутах. Направления с высокими показателями улучшения, такие как «Городское сообщение» и «Международный маршрут», демонстрируют значительный прогресс в оптимизации логистических процессов.

Заключение

Проведенное комплексное исследование процессов оптимизации грузоперевозок на железнодорожном транспорте с приме-

нением передовых технологий искусственного интеллекта позволило получить ряд значимых результатов, свидетельствующих о целесообразности и эффективности внедрения подобных инноваций.

Детальный анализ временных рядов интенсивности грузопотоков методами многомерной статистики на сети из 1042 участков выявил тесную положительную корреляцию (средний коэффициент 0,89) между частотой прохождения грузовых составов и динамикой рыночного спроса на 37 категорий перевозимых товаров. Это определяет объективную необходимость разработки гибких адаптивных алгоритмов оптимизации маршрутизации и логистики на базе аппаратно-программных комплексов обработки больших данных в режиме, близком к реальному времени.

Масштабное компьютерное моделирование (более 100 000 вагонов в 5800 составах за 2 года) погрузочно-разгрузочных операций с учетом характеристик грузов позволило определить оптимальные стратегии размещения, обеспечивающие для 74% формируемых поездов рост среднего объема перевозимого груза в одном рейсе на 5,7%. Ретроспективный анализ геоданных о 4500 контейнерных рейсах методами ансамблевого моделирования установил, что использование адаптивных маршрутов и расписаний на базе прогнозных моделей погодных условий и загруженности участков могло бы сократить среднее время доставки грузов на 8,4%.

Масштабирование результатов по сети дает потенциал роста суммарной провозной способности на 13,6%, что эквивалентно экономии затрат более 470 млн долларов в год. Внедрение разработанного алгоритма динамической оптимизации расписания движения поездов на базе нейросетевых моделей прогнозирования инцидентов позволило снизить среднее время реагирования на нештатные ситуации на 38%, а для критических происшествий (крушения, столкновения) медиана сократилась с 1,9 до 0,82 часов.

Корреляционно-регрессионный анализ показал наибольшую эффективность предложенной оптимизации в зимний период, когда средняя скорость реагирования возросла на 0,21 стандартного отклонения по сравнению с летним сезоном.

Таким образом, результаты многофакторного статистического моделирования на больших данных о грузоперевозках подтверждают гипотезу о том, что внедрение моделей машинного обучения способно обеспечить существенный синергетический эффект за счет оптимизации взаимосвязанных логистических и управленческих процессов на железнодорожном транспорте.

Список литературы

1. Мапохин В.Г., Шабунин А.Б., Ефремов Г.А. Автоматизация диспетчерского управления в ИСУЖТ: опыт внедрения // Труды АО «НИИАС». 2021. Т. 1. Вып. 11. С. 204-214.
2. Акаев А.А., Давыдова О.И., Малков А.С., Шульгин С.Г. Моделирование перспективных торгово-транспортных коридоров в рамках проекта «Один пояс – один путь» // Экономика региона. 2019. Т. 15, Вып. 4. С. 981-995.
3. Зондов К.Х., Медков А.А. Проблемы эволюции транзитных систем и сопряжения инфраструктурных проектов формирования Большого Евразийского партнерства // Экономика и математические методы. 2021. Т. 57, № 2. С. 64-72.
4. Храмцова Н.А., Храмцов Р.И. Эффективность инновационных проектов в транспортных предприятиях // Стратегия бизнеса. 2019. № 9 (65). С. 16-19.
5. Ковальчук А.С., Коваль С.И. Стратегические направления цифровизации железнодорожного транспорта // Экономика и бизнес: теория и практика. 2022. №5-2. С. 63-66.
6. Мухамедова З.Г., Осадчук В.Д., Тулаев А.У. Перспективы использования технологии блокчейн в организации перевозочного процесса и цепочке поставок // Известия Транссиба. 2022. № 2 (50). С. 142-156.
7. Кокурин И.М. Интеллектуальная система управления движением поездов на основе автоматизации диспетчерского регулирования и центрального автоведения // Интеллектуальные системы управления. 2018. № 3. С. 305-312.
8. Макаров В.Л., Ву Ц., Ву З., Хабриев Б.Р., Бахтин А. Р. Мировые торговые войны : сценарные расчёты последствий // Вестник Российской академии наук. 2020. Т. 90, № 2. С. 169-179.
9. Паталахин С.В., Попов А.Э. Системы автономного управления подвижным составом на железной дороге // Цифровая наука. 2020. № 2-3. С. 31-36.
10. Ларин А.Н., Ларина И.В. Цифровизация автотранспортной и железнодорожной отраслей как ключевой элемент цифровой экономики // Известия Транссиба. 2021. №4 (48). С. 109-129.