

УДК 004.032.26

EDN: KVSSFY

Дьячкова В. В., *Свербиненко А. В.*Донбасский государственный технический университет***E-mail: anna-sverbinenko@mail.ru*

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ПРОГНОЗИРОВАНИЯ ПАССАЖИРОПОТОКА ДЛЯ ЖЕЛЕЗНОДОРОЖНОГО ТРАНСПОРТА

В статье представлена нейросетевая модель прогнозирования пассажиропотока для железнодорожного транспорта, показаны основные этапы ее разработки, предложен набор факторов, необходимых для обучения модели. Модель продемонстрировала высокую точность в ходе оценки эффективности и может быть использована при разработке тактических и стратегических мероприятий на различных уровнях управления железной дорогой.

Ключевые слова: прогнозирование пассажиропотока, нейросетевые модели, железнодорожный транспорт, факторы модели, машинное обучение, оптимизация перевозок.

Постановка проблемы. Прогнозирование пассажиропотока на железнодорожном транспорте является ключевой задачей для эффективного управления перевозочными процессами.

Несоответствие между планируемым и фактическим спросом приводит к значительным экономическим потерям: недогрузке или перегрузке составов, нерациональному использованию подвижного состава, увеличению эксплуатационных расходов и снижению качества обслуживания пассажиров.

Проблемы прогнозирования пассажиропотока и применения нейросетевых моделей в транспортной логистике исследовались рядом авторов.

Н. Алхелу [1] разработал метод прогнозирования пассажиропотоков с использованием метода наименьших квадратов, продемонстрировав его эффективность на примере вокзала Латакии.

В. А. Рахаев, Е. Л. Кузина и их соавторы [2] представили комплексное исследование по применению нейросетевого моделирования для прогнозирования пассажиропотоков транспортных компаний, выявив значительное повышение точности прогнозов.

А. С. Журюкин и С. В. Муктепавел [3] провели сравнительный анализ различных методов машинного обучения для прогнозирования железнодорожных пассажиропотоков, доказав преимущество нейросе-

тевых подходов перед традиционными статистическими методами.

А. Я. Бутыркин с соавторами [4] разработали инновационные модели прогнозирования пассажирских перевозок, применимые как для железнодорожного, так и для авиационного транспорта.

А. Н. Михайлов [5] успешно адаптировал методы машинного обучения для анализа пассажиропотока в метрополитене, предложив решения по оптимизации транспортной работы.

В сборнике научных трудов под редакцией Г. А. Тимофеевой и О. В. Куликовой [6] представлен комплексный анализ современных информационных технологий и математических моделей, применяемых для решения транспортных задач.

Е. С. Козин [7] разработал уникальную методику оценки мобильности городского населения с использованием искусственных нейронных сетей, что особенно актуально для планирования транспортной инфраструктуры.

Р. Н. Минниханов с соавторами [8] предложили инновационный подход к прогнозированию транспортных потоков, основанный на агрегировании данных из различных источников.

Х. С. Х. Аламир, Е. В. Заргарян и Ю. А. Заргарян [9] создали эффективную нейросетевую модель для прогнозирования

МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ

ния дорожного трафика, которая может быть адаптирована и для железнодорожных перевозок.

П. В. Тихомиров с соавторами [10] доказали высокую эффективность искусственных нейронных сетей в задачах прогнозирования транспортных процессов.

Несмотря на значительное количество исследований в области прогнозирования пассажиропотоков, вопросы применения современных методов глубокого обучения и их интеграции с традиционными подходами остаются недостаточно изученными, что определяет актуальность дальнейших исследований в данной области.

Постановка задачи. *Целью* данной статьи является разработка нейросетевой модели прогнозирования пассажиропотока для железнодорожного транспорта.

Для достижения данной цели необходимо решить следующие *задачи*:

- провести анализ и определить, на основе каких данных будет обучаться модель;
- реализовать алгоритм предобработки данных;
- определить архитектуру и обучить нейросетевую модель;
- провести оценку качества нейросетевой модели.

Изложение материала. Для построения нейросетевой модели прогнозирования пассажиропотока для железнодорожного транспорта были проанализированы данные, охватывающие широкий спектр факторов, потенциально влияющих на спрос на перевозки.

Рассмотрим информационные потоки, протекающие в ОАО «Российские железные дороги» при прогнозировании пассажиропотока. Информационные потоки условно делятся на:

- входные — формируют базу для расчётов;
- промежуточные (внутренние) — генерируются внутри системы в процессе обработки;
- выходные — передаются во внешние по отношению к прогнозной системе отделы для принятия решений.

Входные потоки формируются на основе первичных данных, поступающих из различных источников:

- формы ЦО-32 — отчёт о перевозках пассажиров дальнего следования;
- формы ЦО-22 (пригород) — содержит информацию о пригородных перевозках;
- маршрутных справочников — содержат перечень действующих маршрутов, соответствующие им станции;
- поездных сведений — содержат данные о составе поездов (тип локомотива, категория вагонов, вместимость);
- расписаний движения поездов;
- формы 1-РЖД (жел) — основные показатели деятельности железнодорожного транспорта общего пользования;
- календарных данных;
- прогноза погоды.

Промежуточные потоки — наиболее интенсивный и сложный уровень взаимодействия информационных потоков.

Эти данные:

- обогащаются и агрегируются;
 - формируют основу прогнозной модели.
- Основные внутренние потоки включают:
- очищенные временные ряды — отфильтрованные данные без пропусков, дубликатов и аномалий;
 - агрегированные таблицы — данные, сгруппированные по временным интервалам (день, неделя, месяц), станциям, маршрутам;
 - параметры моделей и метрики точности;
 - результаты тестирования.

Выходная информация представлена в формате отчетов, предназначенных для дальнейшего анализа и принятия решений.

Анализ информационных потоков в ОАО «Российские железные дороги» позволил сформировать комплексную выборку, учитывающую как исторические закономерности, так и внешние контекстуальные влияния.

Для построения модели использовались данные:

- исторические данные о пассажирских перевозках. Основу выборки составили

МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ

данные из отчетов ОАО «Российские железные дороги», а именно «Отчет о перевозках пассажиров дальнего следования» (форма ЦО-32) и «Отчет о перевозках пассажиров предприятиями пригородного комплекса» (форма ЦО-22 пригород) за период 2019–2024 гг.;

– информация о расписании поездов. Были использованы данные о расписании движения поездов ОАО «Российские железные дороги»;

– характеристики поездов и составов. Данные о типе поезда (пригородный, скорый, экспресс), количестве вагонов в составе и типах вагонов (сидячий, плацкарт, купе и т. д.) позволили учитывать различия в уровне комфорта, цене билета и предпочтениях пассажиров;

– временные характеристики маршрутов. Были использованы данные из отчетов ОАО «Российские железные дороги», а именно «Основные показатели деятельности железнодорожного транспорта общего пользования» (форма 1-РЖД (жел)) за период 2019–2024 гг.;

– календарные данные. Были интегрированы данные о праздничных, выходных и предпраздничных днях, что позволило учесть резкие всплески спроса в периоды повышенной мобильности населения (например, в новогодние праздники, майские выходные и пр.);

– погодные условия. Для маршрутов учитывались ежедневные погодные данные: температура воздуха, осадки, снежные заносы, метели и другие климатические факторы. Были использованы данные из архива погодных данных сервиса «Яндекс. Погода»;

– массовые мероприятия. В выборку включены данные из портала «Архивы России»;

– социально-экономические показатели регионов. Дополнительно были использованы макро- и микросоциальные данные по регионам: численность населения, уровень доходов, занятость, показатели миграционной активности. В выборку был

занесен набор данных из сборников Росстата «Регионы России».

Итоговый структурированный набор данных составил свыше 80 тысяч записей, каждая из которых соответствует уникальной поездке (рейсу) в определённом направлении и на конкретную дату.

Каждая запись в выборке включает следующие ключевые признаки:

- дата и день недели;
- станция отправления и прибытия;
- тип и номер поезда;
- количество вагонов и их категории;
- время отправления и прибытия, длительность маршрута;
- запланированные и фактические остановки;
- задержки и их длительность;
- заполненность поезда;
- погодные параметры на маршруте;
- признаки праздничного или выходного дня;
- наличие и характеристики массовых мероприятий;
- социально-экономические показатели по регионам отправления и прибытия.

Проведённая работа по сбору и структурированию данных помогла создать надёжную основу для построения нейросетевой модели прогнозирования.

Учёт широкого спектра факторов обеспечивает высокую точность прогнозов и позволяет адаптировать модель к изменяющимся условиям эксплуатации железнодорожного транспорта.

Перед обучением нейросетевой модели был выполнен комплекс мероприятий по очистке, преобразованию и отбору данных, направленный на обеспечение корректности, согласованности и информативности входных признаков.

Учитывая гетерогенность исходных данных (временные ряды, категориальные и числовые параметры, внешние события), процесс подготовки был многоэтапным и включал как классические методы предобработки, так и статистическую оценку значимости признаков.

МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ

Этапы подготовки данных:

- удаление записей с высоким уровнем пропусков. Записи, содержащие более 25 % недостающих значений, были исключены из выборки как информационно ненадёжные. Это позволило минимизировать искажения и повысить стабильность модели на этапе обучения;

- обработка пропущенных значений. Для оставшихся пропусков была применена гибридная стратегия восстановления: числовые значения заменялись на медианные значения по маршруту, категориальные и календарные параметры восстанавливались на основе модальных значений, характерных для аналогичных дней недели и сезонов (среднее число пассажиров в понедельник по данному направлению);

- нормализация числовых признаков. Все непрерывные признаки (температура воздуха, длительность поездки, количество проданных билетов и др.) были стандартизованы с использованием Z-преобразования (нормализация к нулевому среднему и единичному стандартному отклонению). Это обеспечило равномерный вклад различных признаков в обучение модели и ускорило сходимость градиентных методов;

- кодирование категориальных признаков. Категориальные признаки (тип поезда, день недели, погодные условия и др.) были преобразованы в бинарные векторы с помощью метода one-hot-кодирования. Данный подход позволил избежать введения ложной иерархии между категориями и обеспечил модели возможность интерпретировать дискретные признаки;

- анализ корреляции признаков. Выполнена оценка парной корреляции между всеми числовыми признаками. Признаки с высоким уровнем линейной зависимости ($|r| > 0,85$) были рассмотрены на предмет избыточности, и из каждой коррелирующей пары был оставлен только один — с наибольшей информативностью в контексте задачи прогнозирования;

- оценка взаимной информации. Проведён отбор признаков на основе критерия

взаимной информации, который позволяет выявить как линейные, так и нелинейные зависимости между входными признаками и целевой переменной (числом пассажиров). Это обеспечило сохранение только действительно значимых факторов, влияющих на поведение модели.

В результате предварительной обработки и отбора были оставлены 20 наиболее значимых признаков, условно сгруппированных по характеру информации:

- темпоральные признаки: день недели, месяц, признак праздничного/выходного дня, сезон (зима, весна, лето, осень);

- операционные характеристики перевозки: тип поезда (пригородный, скорый, экспресс), время отправления (по интервалам суток), протяжённость маршрута (в километрах), количество промежуточных остановок;

- исторические данные: средняя загрузка по данному маршруту за последние 7 дней, средняя загрузка в аналогичный день недели за последние 4 недели;

- метеоусловия: среднесуточная температура, наличие осадков (дихотомический признак), погодные аномалии (метель, сильный ветер, гололёд и др.).

- социальные и событийные факторы: региональный коэффициент транспортного спроса (рассчитанный на основе плотности населения и уровня доходов), наличие массовых мероприятий в зоне обслуживания маршрута, признак «событийного кластера» (наличие сразу нескольких значимых внешних факторов в данной дате/регионе).

Дополнительно была реализована проверка на мультиколлинеарность, и признаки с высоким значением VIF (Variance Inflation Factor) были удалены для повышения устойчивости модели.

Подготовленные данные были разбиты на обучающую, валидационную и тестовую выборки с соотношением 70:15:15, с сохранением сезонной и календарной стратификации.

Это обеспечило сбалансированное представление различных сценариев перевозок

МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ

и позволило адекватно оценить обобщающую способность модели.

Проведённая подготовка данных позволила:

- устранить шумы и противоречия в исходной информации;
- оптимизировать набор признаков, сохранив только релевантные для прогнозирования;
- обеспечить совместимость данных с требованиями нейросетевых алгоритмов.

Было проведено более 80 экспериментов для определения оптимальных параметров модели.

В качестве основной архитектуры была выбрана нейросетевая модель типа многослойного перцептрона (MLP).

Несмотря на наличие более сложных архитектур, таких как LSTM и GRU, многослойный перцептрон (MLP) был выбран за его простоту реализации и высокую интерпретируемость.

По результатам серии экспериментов оптимальной принята архитектура с тремя скрытыми слоями:

- входной слой: 20 нейронов (по числу признаков);
- скрытый слой 1: 64 нейрона (ReLU);
- скрытый слой 2: 32 нейрона (ReLU);
- скрытый слой 3: 16 нейронов (ReLU);
- выходной слой: 1 нейрон с линейной активацией (для регрессии — прогноз числа пассажиров).

Обоснование выбора трёхслойной архитектуры MLP основано на анализе баланса между сложностью модели и её прогностической способностью. Эксперименты показали, что увеличение числа слоёв свыше трёх незначительно улучшает качество прогноза (RMSE на 1–2 %), но снижает интерпретируемость и увеличивает риск переобучения. Напротив, уменьшение числа слоёв приводит к потере способности модели учитывать комплексные взаимодействия факторов. Таким образом, трёхслойная конфигурация обеспечивает оптимальное соотношение точности и устойчивости.

Обучение модели проводилось с использованием:

- функции потерь: среднеквадратичная ошибка (MSE);
- оптимизатора: Adam, learning_rate = 0,001;
- батчей: размер 64;
- эпох: 120 с применением early stopping;
- регуляризации: Dropout = 0,2, L2-регуляризация коэффициентом 0,001.

Средняя абсолютная ошибка на тестовой выборке составила MAE = 27,3, среднеквадратичная ошибка RMSE = 35,9, что при среднем пассажиропотоке 450–500 чел/рейс указывает на высокую точность модели. Для сравнения эффективности различных подходов были построены другие модели прогнозирования (табл. 1).

Результаты тестирования модели продемонстрировали высокую точность: средняя абсолютная ошибка (MAE) составила 27,3, среднеквадратичная ошибка (RMSE) — 35,9, коэффициент детерминации (R^2) — 0,91. Эти значения значительно превосходят показатели базовых моделей, таких как линейная регрессия и случайный лес.

Анализ важности признаков показал, что наибольшее влияние на результат прогнозирования оказывают следующие параметры:

- день недели;
- исторический средний спрос;
- тип поезда;
- протяженность маршрута;
- температура воздуха.

На рисунке 1 представлена диаграмма важности признаков, выявленных с помощью анализа чувствительности выходного значения модели.

Таблица 1

Сравнительная оценка эффективности моделей прогнозирования пассажиропотока

Модель	MAE	RMSE	R^2
Линейная регрессия	42,6	58,4	0,78
Случайный лес (Random Forest)	31,2	41,7	0,87
Нейросетевая модель (MLP)	27,3	35,9	0,91

МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ




Рисунок 1 — Важнейшие признаки прогноза пассажиропотока

Усредненные результаты моделирования по региональным управлениям: Центр, Сибирь, Юг, Дальний Восток представлены в таблице 2.

К Центральному региональному управлению были отнесены Октябрьская, Московская, Северная, Горьковская, Юго-Восточная, Приволжская, Калининградская железные дороги.

К Сибирскому региональному управлению были отнесены Свердловская, Южно-Уральская, Западно-Сибирская, Красноярская, Восточно-Сибирская, Забайкальская железные дороги.

К Южному региональному управлению были отнесены Северо-Кавказская и Куйбышевская железные дороги.

К региональному управлению Дальнего Востока была отнесена Дальневосточная железная дорога.

Наибольшая точность прогноза достигнута для центральных региональных управлений (отклонение $-1,7\%$), что связано с высокой стабильностью спроса и наличием обширных исторических данных.

Небольшое завышение прогноза для Сибири ($+2,8\%$) и Дальнего Востока ($+4,1\%$) возможно объясняется снижением туристической активности, не учтенной в модели.

Список источников

1. Алхелу Н. Прогнозирование железнодорожных пассажиропотоков методом наименьших квадратов (на примере вокзала Латакии) // Академик Владимир Николаевич Образцов —

Таблица 2
Средний пассажиропоток в апреле 2025 года по регионам, чел/рейс

Региональное управление	Прогнозное значение	Фактическое значение
Центр	618	629
Сибирь	440	428
Юг	390	403
Дальний Восток	330	317

Занижение прогноза для южных региональных управлений ($-3,2\%$) может быть связано с неожиданными погодными аномалиями (низкая температура, дожди и прочее), которые снизили спрос на поездки.

Важным преимуществом разработанной модели является её потенциал для интеграции с интеллектуальными системами поддержки принятия решений транспортных организаций, что позволяет автоматизировать процесс прогнозирования пассажиропотоков и оперативно реагировать на изменения спроса. Практическое внедрение прогнозной будет способствовать повышению точности планирования перевозок и, как следствие, более эффективному распределению ресурсов и снижению операционных издержек.

Выводы и направление дальнейших исследований. В результате проведенного исследования разработана нейросетевая модель прогнозирования пассажиропотока для железнодорожного транспорта, продемонстрировавшая высокую точность при оценке её эффективности. Результаты выполненных исследований могут быть использованы при разработке тактических и стратегических мероприятий на различных уровнях управления железной дорогой. В качестве направления дальнейших исследований предполагается интеграция модели с интеллектуальными системами поддержки принятия решений.

МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ

основоположник транспортной науки : Труды международной научно-практической конференции, Москва, 17 ноября 2023 года. М. : Университетская книга, 2023. С. 10–16. EDN CPFXIR

2. Нейросетевое моделирование в прогнозировании пассажиропотоков транспортных компаний / В. А. Рахаев, Е. Л. Кузина, М. А. Василенко [и др.] // Наука и бизнес: пути развития. 2022. № 10 (136). С. 64–73. EDN HIXRSA

3. Журюкин А. С., Муктепавел С. В. Прогнозирование пассажиропотока на железнодорожном транспорте с применением машинного обучения // Вестник науки. 2025. № 4 (85). Т. 3. С. 751–761. URL: <https://www.вестник-науки.рф/article/22438> (дата обращения: 25.05.2025).

4. Бутыркин А. Я., Куликова Е. Б., Мадяр О. Н. Модели прогнозирования пассажирских перевозок на железнодорожном и авиационном транспорте // Наука и техника транспорта. 2021. № 1. С. 19–27. EDN WMYYSLS

5. Михайлов А. Н. Машинное обучение для анализа пассажиропотока в метро: оптимизация работы транспорта и прогнозирование нагрузки // Вестник науки. 2024. № 12 (81). С. 1458–1462. URL: <https://cyberleninka.ru/article/n/mashinnoe-obuchenie-dlya-analiza-passazhiropotoka-v-metro-optimizatsiya-raboty-transporta-i-prognozirovanie-nagruzki> (дата обращения: 25.05.2025).

6. Применение информационных технологий и математического моделирования при решении исследовательских задач : сборник научных трудов / под науч. ред. Г. А. Тимофеевой, О. В. Куликовой. Вып. 5 (253). Екатеринбург : Уральский государственный университет путей сообщения, 2023. 157 с. EDN PIKEBD

7. Козин Е. С. Оценка структуры подвижности населения города с использованием метода искусственных нейронных сетей // Прогрессивные технологии в транспортных системах : материалы XVII международной научно-практической конференции, Оренбург, 17–18 ноября 2022 г. Оренбург : Оренбургский государственный университет, 2022. С. 273–277. EDN LJCMTH

8. Подход к прогнозированию транспортных потоков, основанный на агрегировании информации, получаемой из различных источников / Р. Н. Минниханов, М. В. Дагаева, И. В. Аникин [и др.] // Вестник НЦБЖД. 2020. № 4 (46). С. 128–137. EDN JIFMRI

9. Аламир Х. С., Заргарян Е. В., Заргарян Ю. А. Модель прогнозирования транспортного потока на основе нейронных сетей для предсказания трафика на дорогах // Известия ЮФУ. Технические науки. 2021. № 6 (223). С. 124–132. URL: <https://cyberleninka.ru/article/n/model-prognozirovaniya-transportnogo-potoka-na-osnove-neyronnyh-setey-dlya-predskazaniya-trafika-na-dorogah> (дата обращения: 25.05.2025).

10. Применение искусственных нейронных сетей в задачах прогнозирования транспортных процессов / П. В. Тихомиров, В. В. Сиваков, В. В. Камынин, С. С. Синицын // Мир транспорта и технологических машин. 2022. № 2 (77). С. 116–124. DOI: 10.33979/2073-7432-2022-77-2-116-124. EDN CWTDHY

© Дьячкова В. В., Свербиненко А. В., 2025

**Рекомендована к печати д.э.н., проф. каф. ИСИБ ДонГТУ Бизяновым Е. Е.,
руководителем отдела стратегического развития и управления проектами
ЛГАУ имени К. Е. Ворошилова, к.э.н. Кунченко А. В.**

Статья поступила в редакцию 11.06.2025.

СВЕДЕНИЯ ОБ АВТОРАХ

Дьячкова Виктория Викторовна, канд. экон. наук, доцент каф. информационных технологий Донбасский государственный технический университет, г. Алчевск, Россия

Свербиненко Анна Валерьевна, Донбасский государственный технический университет, г. Алчевск, Россия, e-mail: anna-sverbinenko@mail.ru

Diachkova V. V., *Sverbinenko A. V. (Donbass State Technical University, Alchevsk, Russia,
*e-mail: anna-sverbinenko@mail.ru)

NEURAL NETWORK MODEL FOR PREDICTING PASSENGER FLOW IN RAILWAY TRANSPORT

The article presents a neural network model for predicting passenger flow in railway transport, outlines the main stages of its development, and proposes a set of factors necessary for training the model. The model demonstrated high accuracy in the course of assessing the effectiveness and can be used in developing tactical and strategic measures at various levels of railway management.

Key words: passenger flow prediction, neural network model, railway transport, quotient model, machine learning, transportation optimization.

References

1. Alhelu N. Predicting railway passenger flows using the smallest squares (as exemplified at Latakia station) [Prognozirovanie zheleznodorozhnyh passazhiropotokov metodom naimen'shih kvadratov (na primere vokzala Latakii)]. Akademik Vladimir Nikolaevich Obrazcov — osnovopolozhnik transportnoj nauki : trudy mezhdunarodnoj nauchno-prakticheskoy konferencii, Moskva, 17 noyabrya 2023 goda. M. : Universitetskaya kniga. 2023. Pp. 10–16. EDN CPFIXR
2. Rakhaev V. A., Kuzina E. L., Vasilenko M. A. [et al.]. Neural network modeling for predicting passenger flow in transport companies [Nejrosetevoie modelirovanie v prognozirovanii passazhiropotokov transportnyh kompanij]. Science and business: development ways. 2022. No. 10 (136). Pp. 64–73. EDN HIXRSA
3. Zhuryukin A. S., Muktepavel S. V. Predicting passenger flow on railway transport through the use of machine training [Prognozirovanie passazhiropotoka na zheleznodorozhnom transporte s primeneniem mashinnogo obucheniya]. Vestnik nauki No. 4 (85). Vol. 3. 2025. Pp. 751–761. URL: <https://www.vestnik-nauki.pf/article/22438> (date of treatment: 25.05.2025).
4. Butyrkin A. Ya., Kulikova E. B., Madyar O. N. Models for predicting passenger flow in railway and air transport [Modeli prognozirovaniya passazhirskih perevozok na zheleznodorozhnom i aviacionnom transporte]. Science and Technology in Transport. 2021. No. 1. Pp. 19–27. EDN WMYLRS
5. Mikhailov A. N. Machine training for analyzing passenger flow in the subway: optimizing transport operations and load forecasting [Mashinnoe obuchenie dlya analiza passazhiropotoka v metro: optimizatsiya raboty transporta i prognozirovanie nagruzki]. Vestnik nauki. 2024. No. 12 (81). Pp. 1458–1462. URL: <https://cyberleninka.ru/article/n/mashinnoe-obuchenie-dlya-analiza-passazhiropotoka-v-metro-optimizatsiya-raboty-transporta-i-prognozirovanie-nagruzki> (date of treatment: 25.05.2025).
6. Application of information technology and mathematical modeling in solving research problems : Collection of scientific papers [Primenenie informacionnyh tekhnologij i matematicheskogo modelirovaniya pri reshenii issledovatel'skih zadach : Sbornik nauchnyh trudov]. Under scientific editorship Timofeevoi G. A., Kulikovo O. V. Vol. Iss. 5 (253). Ekaterinburg : Ural State University of Railway Transport. 2023. 157 p. EDN PIKEBD
7. Kozin E. S. Assessing the structure of population mobility using artificial neural networks [Ocenka struktury podvizhnosti naseleniya goroda s ispol'zovaniem metoda iskusstvennyh nejronnyh setej]. Progressivnye tekhnologii v transportnyh sistemah : materialy XVII mezhdunarodnoj nauchno-prakticheskoy konferencii. Orenburg. 17–18 noyabrya 2022 goda. Orenburg State University. 2022. Pp. 273–277. EDN LJCMTX
8. Minnikhanov R. N., Dagaeva M. V., Anikin I. V. [et al.]. An approach to predicting traffic based on aggregation of information obtained from different sources [Podhod k prognozirovaniyu transportnyh potokov, osnovannyj na agregirovanii informacii, poluchaemoj iz razlichnyh istochnikov]. Vestnik NTsBZhD. 2020. No. 4 (46). Pp. 128–137. EDN JIFMRI
9. Alamir H. S., Zargaryan E. V., Zargaryan Yu. A. Traffic flow prediction model based on neural networks for road traffic prediction [Model' prognozirovaniya transportnogo potoka na osnove nejronnyh setej dlya predskazaniya trafika na dorogah]. Izvestiya YuFU. Tekhnicheskie nauki. 2021. No. 6 (223). Pp. 124–132. URL: <https://cyberleninka.ru/article/n/model-prognozirovaniya-transportnogo-potoka-na-osnove-neyronnyh-setey-dlya-predskazaniya-trafika-na-dorogah> (date of treatment: 25.05.2025).

МАТЕМАТИЧЕСКИЕ, СТАТИСТИЧЕСКИЕ И ИНСТРУМЕНТАЛЬНЫЕ МЕТОДЫ В ЭКОНОМИКЕ

10. Tikhomirov P. V., Sivakov V. V., Kamynin V. V., Sinicyn S. S. Application of artificial neural networks in transport process prediction [Primenenie iskusstvennyh neyronnyh setej v zadachah prognozirovaniya transportnyh processov]. *World of transport and technological machinery*. 2022. No. 2 (77). Pp. 116–124. DOI: 10.33979/2073-7432-2022-77-2-116-124. EDN CWTDHY

INFORMATION ABOUT THE AUTHORS

Diachkova Victoria Victorovna, PhD in Economics, Assistant Professor of the Department of Information Technologies
Donbass State Technical University,
Alchevsk, Russia

Sverbinnenko Anna Valerievna,
Donbass State Technical University,
Alchevsk, Russia, e-mail: anna-sverbinnenko@mail.ru