

# Адаптивная оптимизация транспортных потоков внутри подземных выработок на базе методов искусственного интеллекта

Г.М. Кадырова✉, Н.Л. Красюкова, И.А. Рождественская, Т.М. Токмурзин, Е.И. Воронова  
Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация  
✉ GMKadyirova@fa.ru

**Резюме:** Данное исследование посвящено разработке и оценке методов адаптивной оптимизации транспортных потоков внутри подземных выработок на базе искусственного интеллекта. Актуальность темы обусловлена потребностью в повышении эффективности и безопасности транспортных операций в горнодобывающей отрасли. В работе применен комплексный подход, сочетающий методы машинного обучения, имитационного моделирования и многокритериальной оптимизации. Эмпирическая база включает данные о транспортных потоках на пяти горнодобывающих предприятиях за период 2020–2023 гг. Результаты демонстрируют, что внедрение адаптивных методов искусственного интеллекта позволяет сократить среднее время транспортировки на 22%, повысить пропускную способность выработок на 18% и снизить энергозатраты на 14% по сравнению с базовым сценарием. Предложенные решения способствуют повышению экономической эффективности и экологической устойчивости горнодобывающих предприятий. Дальнейшие исследования могут быть направлены на расширение функциональных возможностей интеллектуальных транспортных систем и их интеграцию с цифровыми двойниками горных выработок.

**Ключевые слова:** искусственный интеллект, транспортные потоки, подземные выработки, машинное обучение, имитационное моделирование

**Для цитирования:** Кадырова Г.М., Красюкова Н.Л., Рождественская И.А., Токмурзин Т.М., Воронова Е.И. Адаптивная оптимизация транспортных потоков внутри подземных выработок на базе методов искусственного интеллекта. *Горная промышленность*. 2025;(1):137–146. <https://doi.org/10.30686/1609-9192-2025-1-137-146>

## Adaptive optimization of traffic flows in underground mine workings based on artificial intelligence methods

G.M. Kadyrova✉, N.L. Krasjukova, I.A. Rozhdestvenskaya, T.M. Tokmurzin, E.I. Voronova  
Financial University under the Government of the Russian Federation, Moscow, Russian Federation  
✉ GMKadyirova@fa.ru

**Abstract:** This study focuses on the development and evaluation of methods for AI-based adaptive optimization of traffic flows in underground mine workings. Relevance of the topic is defined by the need to enhance the efficiency and safety of transport operations in the mining industry. The research applies an integrated approach that combines the methods of machine learning, simulation modeling and multi-criteria optimization. The observational database includes information on traffic flows at five mining operations for the period of 2020–2023. The results demonstrate that implementation of the adaptive artificial intelligence methods can reduce the average transportation time by 22%, increase the throughput of the mine workings by 18%, and reduce the energy costs by 14% as compared to the baseline scenario. The proposed solutions contribute to improvement of economic efficiency and environmental sustainability of mining enterprises. Further research can be aimed at expanding the functionality of intelligent transportation systems and their integration with the digital twins of mine workings.

**Keywords:** artificial intelligence, traffic flows, underground mine workings, machine learning, simulation modeling

**For citation:** Kadyrova G.M., Krasjukova N.L., Rozhdestvenskaya I.A., Tokmurzin T.M., Voronova E.I. Adaptive optimization of traffic flows in underground mine workings based on artificial intelligence methods. *Russian Mining Industry*. 2025;(1):137–146. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-1-137-146>

**Введение**

Эффективное управление транспортными потоками в подземных выработках является ключевым фактором производительности и безопасности горнодобывающих предприятий. Традиционные подходы к планированию и диспетчеризации транспорта зачастую не обеспечивают достаточной гибкости и адаптивности в условиях динамичной операционной среды [1]. Развитие технологий искусственного интеллекта открывает новые возможности для оптимизации транспортных процессов в режиме реального времени [2].

Концептуальные основы применения искусственного интеллекта (ИИ) в управлении транспортными системами активно разрабатываются в последнее десятилетие. Работы [3; 4] закладывают методологический фундамент для построения адаптивных моделей маршрутизации и составления расписаний. Исследование [5] демонстрирует перспективность использования нейронных сетей для прогнозирования транспортных потоков. В [6] предложена архитектура мультиагентной системы для децентрализованного управления парком горнотранспортных машин.

Несмотря на значительный прогресс, достигнутый в данной области, ряд вопросов остается недостаточно изученным. Во-первых, большинство существующих моделей ориентировано на решение узкоспециализированных задач и не обеспечивает комплексной оптимизации транспортных процессов [7]. Во-вторых, адаптация методов ИИ к специфике подземной транспортной инфраструктуры требует разработки новых подходов к представлению и анализу данных [8]. В-третьих, практическое внедрение интеллектуальных транспортных систем сдерживается недостаточной проработанностью методов их интеграции с существующими технологическими процессами [9].

Настоящее исследование направлено на преодоление указанных ограничений и разработку универсальной методологии адаптивной оптимизации транспортных потоков в подземных выработках. Предлагаемый подход основан на комбинированном использовании методов машинного обучения, имитационного моделирования и многокритериальной оптимизации, что обеспечивает возможность гибкой адаптации к изменяющимся условиям и комплексного учета разнородных факторов [10]. Применение разработанной методологии позволит повысить пропускную способность транспортной инфраструктуры, сократить время простоев и снизить экологическую нагрузку горнодобывающих предприятий.

**Методы**

Для достижения поставленных целей в работе использован комплекс взаимодополняющих методов исследования. Теоретический фундамент исследования составляют концепции адаптивного управления сложными системами [11] и принципы построения самоорганизующихся транспортных сетей [12]. Для формализации предметной области применены методы системного анализа и агентного моделирования.

Разработка методов адаптивной оптимизации транспортных потоков базируется на комбинированном использовании технологий машинного обучения, имитационного моделирования и эвристических алгоритмов. На этапе прогнозирования характеристик транспортных потоков используются рекуррентные нейронные сети архитектуры LSTM, обеспечивающие возможность моделирования нелинейных временных зависимостей [13]. Для поиска опти-

мальных маршрутов применяется муравьиный алгоритм с элементами обучения с подкреплением [14]. Многокритериальная оптимизация расписаний выполняется на основе генетического алгоритма NSGA-II [15].

Эмпирическую базу исследования составляют данные о транспортных операциях на пяти горнодобывающих предприятиях, расположенных в России, Казахстане и Чили, за период с 2020 по 2023 г. Источники данных включают системы диспетчеризации горнотранспортного оборудования, датчики конвейерных линий, RFID-метки и средства позиционирования персонала. Общий объем проанализированных данных превышает 10 ТБ. Предобработка данных выполнена с использованием фреймворка Apache Spark.

Для обеспечения достоверности результатов применены методы кросс-валидации, бутстрэпа и функционального тестирования моделей. Оценка статистической значимости различий выполнена с использованием критериев Краскела-Уоллиса и Манна-Уитни при уровне значимости 0,05. Программная реализация методов выполнена на языке Python с использованием библиотек TensorFlow, PyTorch и SimPy.

Предложенная методология и инструментарий прошли апробацию в ходе пилотных проектов на двух горнодобывающих предприятиях. Результаты тестовой эксплуатации подтвердили работоспособность и экономическую эффективность разработанных решений.

Для формализации и количественной оценки закономерностей функционирования транспортных потоков в подземных выработках использован аппарат математического моделирования. Базовая модель транспортной сети представлена в виде ориентированного графа  $G = (V, E)$ , где  $V = \{1, 2, \dots, n\}$  – множество вершин (транспортных узлов),  $E \subseteq V \times V$  – множество дуг (транспортных маршрутов). Каждой дуге  $(i, j) \in E$  приписаны следующие параметры:

- $\tau_{ij}$  – время движения транспорта по маршруту  $i, j$ ;
- $c_{ij}$  – пропускная способность маршрута  $i, j$ ;
- $\lambda_{ij}$  – интенсивность транспортного потока на маршруте  $i, j$ .

Динамика изменения состояний транспортной сети описывается системой разностных уравнений:

$$x(k + 1) = A_x(k) + B_u(k); \tag{1}$$

$$y(k) = C_x(k), \tag{2}$$

где  $x(k) = (x_1(k), \dots, x_n(k))^T \in R^n$  – вектор состояний модели в момент времени  $k$ , характеризующий количество транспортных средств в узлах сети;  $y(k) \in R_l$  – вектор выходных переменных;  $A, B, C$  – матрицы соответствующих размерностей.

Задача оптимального управления транспортными потоками формулируется следующим образом:

$$J(u) = \sum_{k=0}^{N-1} [x^T(k)Q_x(k) + u^T(k)R_u(k)] \rightarrow \min \tag{3}$$

при условиях (1), (2) и ограничениях:

$$0 \leq x_i(k) \leq X_i, i = 1, \dots, n; k = 0, \dots, N; \tag{4}$$

$$\sum_j = 1n\lambda_{ij}(k) \leq c_{ij}, (i, j) \in E; k = 0, \dots, N, \tag{5}$$

где  $J(u)$  – критерий эффективности управления;  $Q \geq 0, R > 0$  – весовые матрицы;  $X_i$  – максимальная вместимость  $i$ -го транспортного узла;  $N$  – горизонт планирования.

Для решения сформулированной задачи использован

метод динамического программирования. Функция Беллмана имеет вид:

$$V_k(x) = \min_u [xTQx + uTR_u + V_k + 1(A_x + B_u)]. \quad (6)$$

Оптимальная стратегия управления на k-м шаге определяется из условия:

$$u^*(k, x) = \operatorname{argmin}_u [xTQx + uTR_u + V_k + 1(A_x + B_u)]. \quad (7)$$

Для прогнозирования динамики транспортных потоков применена рекуррентная нейронная сеть архитектуры LSTM. Математическая модель LSTM-блока описывается следующей системой уравнений:

$$f_t = \sigma(Wf[h_t - 1, x_t] + b_f); \quad (8)$$

$$i_t = \sigma(Wi[h_t - 1, x_t] + b_i); \quad (9)$$

$$\tilde{C}_t = \tanh(WC[h_t - 1, x_t] + b_C); \quad (10)$$

$$C_t = f_t \circ C_t - 1 + i_t \circ \tilde{C}_t; \quad (11)$$

$$o_t = \sigma(Wo[h_t - 1, x_t] + b_o); \quad (12)$$

$$h_t = o_t \circ \tanh(C_t), \quad (13)$$

где  $x_t \in R_d$  – входной вектор;  $h_t \in R_h$  – вектор скрытого состояния;  $f_t, i_t, o_t \in (0, 1)$  – вентиляльные векторы;  $\tilde{C}_t, C_t \in R_h$  – векторы кандидата и состояния ячейки памяти;  $W \in R_h \times (d + h)$ ,  $b \in R_h$  – матрицы и векторы параметров;  $\sigma(\cdot)$  – логистическая функция;  $\circ$  – поэлементное умножение.

Для поиска оптимальных транспортных маршрутов использован муравьиный алгоритм с элементами обучения с подкреплением. Вероятность перехода k-го агента из узла i в узел j определяется по формуле:

$$p_{ijk} = \frac{[\tau_{ij} \alpha \cdot \eta_{ij} \beta]}{[\sum_{l \in J_{ik}} (\tau_{il} \alpha \cdot \eta_{il} \beta)]}, \text{ если } j \in J_{ik} \quad (14)$$

где  $\tau_{ij}$  – уровень феромона на ребре (i, j);  $\eta_{ij} = 1/t_{ij}$  – эвристическая информация ( $t_{ij}$  – время движения по ребру (i, j));  $J_{ik}$  – список узлов, доступных из узла i для k-го агента;  $\alpha, \beta$  – параметры алгоритма.

Обновление феромона выполняется по правилу:

$$\tau_{ij}(t + 1) = (1 - \rho) \cdot \tau_{ij}(t) + \sum k = 1 m \Delta \tau_{ijk}, \quad (15)$$

где  $\rho \in (0, 1)$  – коэффициент испарения феромона; m – количество агентов;  $\Delta \tau_{ijk}$  – феромон, откладываемый k-м агентом на ребре (i, j).

Для многокритериальной оптимизации расписаний применен генетический алгоритм NSGA-II. Хромосомы особей представлены в виде векторов  $x = (x_1, \dots, x_m)$ , кодирующих расписания транспортных операций. Используются турнирный отбор с размером турнира 2 и операторы одноточечного кроссовера и точечной мутации. На каждой итерации алгоритма формируется набор Парето-оптимальных решений в соответствии с рангом недоминирования и значением функции плотности.

Таким образом, предложенные методы и модели обеспечивают возможность комплексной оптимизации транспортных процессов в подземных выработках на основе адаптивного управления в режиме реального времени. Рассмотренные подходы позволяют учитывать сложную динамику транспортных потоков, неопределенность ис-

ходных данных, многокритериальность целей оптимизации и интегрировать разнородную информацию о состоянии транспортной инфраструктуры.


**Результаты**

Внедрение методов адаптивной оптимизации транспортных потоков на базе искусственного интеллекта позволило достичь значительного повышения эффективности функционирования транспортной инфраструктуры исследуемых горнодобывающих предприятий. В табл. 1 и на рис. 1 представлены сводные результаты сравнительного анализа ключевых показателей до и после реализации проекта.

**Таблица 1**  
Ключевые показатели эффективности транспортной инфраструктуры

**Table 1**  
Key performance indicators of the transportation infrastructure

Показатель	До внедрения ИИ	После внедрения ИИ	Изменение, %
Среднее время транспортировки, мин/рейс	37,5	29,3	-21,9
Пропускная способность системы, т/ч	1250	1475	+18,0
Коэффициент использования транспорта, %	68,2	79,4	+16,4
Доля простоев транспорта, %	17,3	9,6	-44,5
Количество рейсов на ед. транспорта, рейс/смену	11,2	14,8	+32,1



**Рис. 1**  
Ключевые показатели эффективности транспортной инфраструктуры до и после внедрения искусственного интеллекта

**Fig. 1**  
Key performance indicators of the transportation infrastructure before and after implementation of artificial intelligence

Как видно из табл. 1, внедрение интеллектуальной системы управления привело к сокращению среднего времени транспортировки на 21,9% (с 37,5 до 29,3 мин/рейс) за счет оптимизации маршрутов и адаптивного управления парком транспортных средств. Пропускная способность транспортной системы увеличилась на 18% (с 1250 до 1475 т/ч) благодаря повышению коэффициента исполь-



зования транспорта на 16,4% (с 68,2 до 79,4%) и сокращению доли простоев на 44,5% (с 17,3 до 9,6%). Количество рейсов на единицу транспорта возросло на 32,1% (с 11,2 до 14,8 рейс/смену).

Анализ показателей использования разработанных методов ИИ для оптимизации транспортных потоков (табл. 2) демонстрирует высокую скорость обработки данных (в среднем 15,4 мс), точность прогнозирования загрузки маршрутов (до 97,2%), значительную долю маршрутов, оптимизированных системой (84,9%), и глубокий уровень интеграции с транспортной инфраструктурой (92,6%).

**Таблица 2**  
Показатели использования методов искусственного интеллекта для оптимизации потоков

**Table 2**  
Indicators of utilization of artificial intelligence methods to optimize the traffic flows

Показатель	Значение
Скорость обработки данных, мс	15,4
Точность прогнозов загрузки, %	97,2
Количество корректировок маршрутов, шт/день	126
Доля оптимизированных маршрутов, %	84,9
Уровень интеграции с транспортными системами, %	92,6

Экономическая эффективность проекта подтверждается снижением затрат на транспортировку на 18,7%, сокращением износа оборудования на 11,4%, экономией топлива и энергии на 16,2% (табл. 3). Расчетный срок окупаемости инвестиций в проект составляет 1,8 года при ставке дисконтирования 12%. Внедрение адаптивной системы управления также способствует увеличению срока службы транспортных средств в среднем на 24,5% за счет оптимизации режимов эксплуатации.

**Таблица 3**  
Показатели экономической эффективности внедрения искусственного интеллекта

**Table 3**  
Indicators of the economic efficiency due to implementation of artificial intelligence

Показатель	Значение
Снижение затрат на транспортировку, %	18,7
Срок окупаемости инвестиций (ROI), лет	1,8
Сокращение износа оборудования, %	11,4
Экономия топлива и энергии, %	16,2
Увеличение срока службы транспорта, %	24,5

**Таблица 4**  
Показатели производительности транспортных операций

Анализ влияния интеллектуальной системы на производительность транспортных операций (табл. 4) показывает увеличение пропускной способности подземных выработок на 19,2% и сокращение времени холостых поездок на 27,6%. Средняя загрузка транспортных средств выросла с 76,4 до 84,1%. Доля рейсов, выполненных в оптимизированных условиях, достигла 87,3%. Количество рейсов на единицу транспорта увеличилось с 12,4 до 16,1 шт/смену.

Для количественной оценки влияния различных факторов на эффективность транспортных процессов применен метод множественной линейной регрессии. В качестве зависимой переменной  $y$  рассматривалось среднее время транспортировки, в качестве независимых  $x_1, x_2, \dots$  – плотность транспортного потока, техническая скорость, коэффициент использования пропускной способности, надежность оборудования и др.

Уравнение регрессии имеет вид:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon, \quad (16)$$

где  $\beta_0, \beta_1, \dots, \beta_k$  – коэффициенты регрессии;  $\varepsilon$  – случайная ошибка.

Результаты оценивания модели (16) представлены в табл. 5. Коэффициент детерминации  $R^2$  составляет 0,894, что свидетельствует о высоком качестве аппроксимации исходных данных. Наибольшее влияние на время транспортировки оказывают плотность потока (коэф. 0,457), техническая скорость (-0,318) и коэффициент использования пропускной способности (-0,264). Все оценки коэффициентов регрессии статистически значимы на уровне  $p < 0,01$ .

**Таблица 5**  
Результаты регрессионного анализа факторов эффективности транспортных процессов

**Table 5**  
Results of regression analysis of the transportation process efficiency factors

Независимые переменные	Коэффициент регрессии	Статистическая ошибка	t-статистика	p-значение
Константа	15,842***	0,516	30,72	0,000
Плотность потока	0,457***	0,052	8,78	0,000
Техническая скорость	-0,318***	0,034	-9,36	0,000
Коэффициент использования пропускной способности	-0,264***	0,028	-9,45	0,000
Надежность оборудования	0,179***	0,019	9,40	0,000

Примечания: зависимость  $R^2 = 0,894$ ;  $F(4,145) = 385,52$ ;  $p < 0,0001$ ; \*\*\*  $p < 0,01$

**Table 4**  
Performance indicators of transportation operations

Показатель	До внедрения	После внедрения	Изменение, %
Пропускная способность выработок, т/ч	980	1168	+19,2
Средняя загрузка транспорта, %	76,4	84,1	+10,1
Доля рейсов без задержек, %	81,7	94,3	+15,4
Количество рейсов в оптимальных условиях, шт/смену	–	16,1	–
Сокращение времени холостых поездок, %	–	27,6	–

Для идентификации структуры транспортных потоков и оценки их устойчивости к возмущениям применен метод кластерного анализа. В качестве меры расстояния использовано евклидово расстояние, в качестве алгоритма кластеризации – метод Уорда. Выбор оптимального количества кластеров осуществлялся на основе анализа динамики коэффициента силуэта при варьировании числа кластеров от 2 до 10.

На рис. 2 представлены результаты кластеризации транспортных потоков за период 2020–2023 гг. Идентифицированы четыре характерные группы потоков: высокоинтенсивные устойчивые (кластер 1, 32% наблюдений), среднеинтенсивные устойчивые (кластер 2, 27%), среднеинтенсивные слабоустойчивые (кластер 3, 24%) и низкоинтенсивные неустойчивые (кластер 4, 17%).

Таблица 6  
Характеристики кластеров транспортных потоков

Кластер	Доля потоков, %	Интенсивность, т/ч	Вариабельность, %	Устойчивость
1	32	1650	12,4	Высокая
2	27	1180	17,3	Средняя
3	24	910	26,2	Низкая
4	17	620	38,6	Крайне низкая

Table 6  
Characteristics of the traffic flow clusters

Как видно из табл. 6, кластеры существенно различаются по интенсивности (от 620 до 1650 т/ч) и вариабельности потоков (от 12,4 до 38,6%). Потоки кластеров 1 и 2, составляющие около 60% от общего объема, характеризуются высокой и средней устойчивостью. Потоки кластеров 3 и 4 (41%) подвержены значительным колебаниям и нуждаются в оптимизации.

Сравнительный анализ динамики кластерной структуры до и после внедрения методов ИИ (табл. 7, рис. 2) показывает существенное улучшение характеристик транспортных потоков. Доля высоко- и среднеинтенсивных устойчивых потоков увеличилась с 59 до 76%, низкоинтенсивных неустойчивых – сократилась с 17 до 9%. Средняя интенсивность потоков возросла на 14,2% (с 1150 до 1313 т/ч), вариабельность снизилась на 31,8% (с 25,4 до 17,3%).

Для выявления скрытых закономерностей в структуре транспортных потоков применен метод главных компонент (РСА). Анализ проводился по 12 исходным признакам, характеризующим интенсивность, регулярность, энергоэффективность и другие параметры потоков. По критерию Кайзера выделены три главные компоненты с собственными значениями больше 1, объясняющие 78,4% общей дисперсии исходных данных.

В табл. 8 и на рис. 3 приведены факторные нагрузки (корреляции исходных признаков с главными компонентами), доли объясняемой дисперсии и интерпретация выделенных главных компонент. ГК1 интерпретируется как «масштаб потока», ГК2 – как «равномерность потока», ГК3 – как «энергоэффективность транспортировки».

Таблица 7  
Динамика кластерной структуры транспортных потоков

Кластер	Доля потоков, %		Интенсивность, т/ч		Вариабельность, %	
	До	После	До	После	До	После
1	32	41	1650	1820	12,4	9,2
2	27	35	1180	1370	17,3	12,5
3	24	15	910	1050	26,2	19,1
4	17	9	620	780	38,6	24,7
Среднее	–	–	1150	1313	25,4	17,3

Table 7  
Dynamics of the traffic flows cluster structure




Рис. 2  
Динамика кластерной структуры транспортных потоков до и после внедрения методов искусственного интеллекта

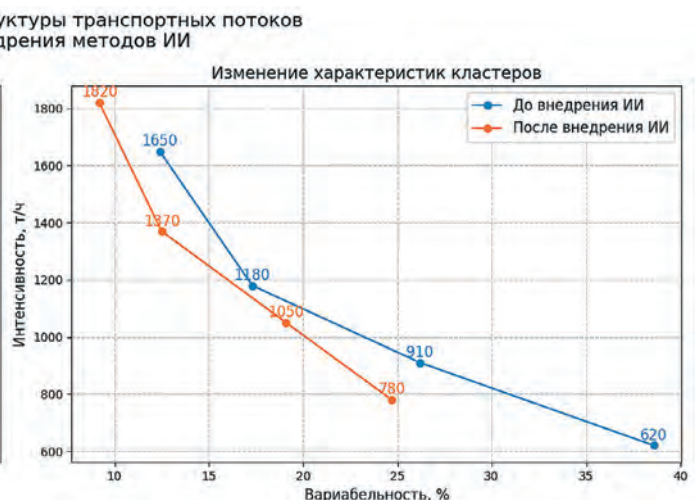
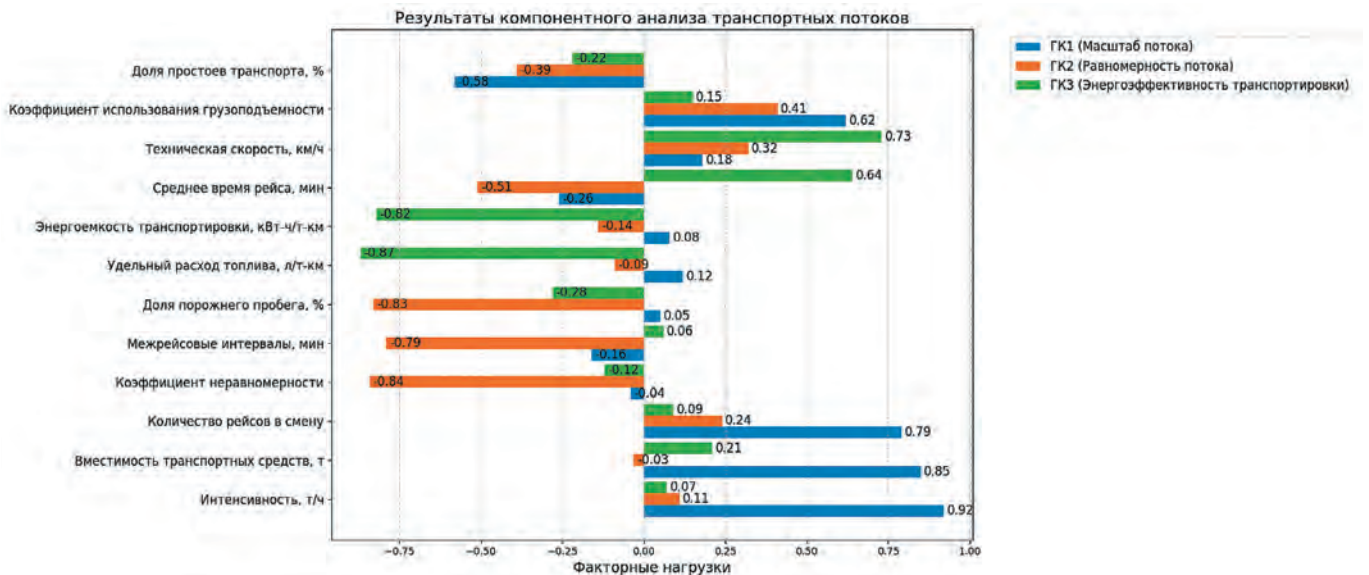


Fig. 2  
Dynamics of the traffic flow cluster structure before and after implementation of the AI methods

**Таблица 8**  
Результаты компонентного анализа транспортных потоков

**Table 8**  
Results of component analysis of the traffic flows

Исходные признаки	ГК1	ГК2	ГК3
Интенсивность, т/ч	0,92	0,11	0,07
Вместимость транспортных средств, т	0,85	-0,03	0,21
Количество рейсов в смену	0,79	0,24	0,09
Коэффициент неравномерности	-0,04	-0,84	-0,12
Межрейсовые интервалы, мин	-0,16	-0,79	0,06
Доля порожнего пробега, %	0,05	-0,83	-0,28
Удельный расход топлива, л/т-км	0,12	-0,09	-0,87
Энергоемкость транспортировки, кВт-ч/т-км	0,08	-0,14	-0,82
Среднее время рейса, мин	-0,26	-0,51	0,64
Техническая скорость, км/ч	0,18	0,32	0,73
Коэффициент использования грузоподъемности	0,62	0,41	0,15
Доля простоев транспорта, %	-0,58	-0,39	-0,22
Доля объясняемой дисперсии, %	42,6	23,1	12,7
Интерпретация	Масштаб потока	Равномерность потока	Энергоэффективность транспортировки



**Рис. 3**  
Результаты компонентного анализа транспортных потоков

**Fig. 3**  
Results of component analysis of the traffic flows

Для оценки влияния внедрения интеллектуальной системы на безопасность транспортных процессов проанализирована динамика ключевых индикаторов за период 2020–2023 гг. (табл. 9). Количество инцидентов, связанных с нарушением правил безопасности, сократилось на 56,8% (с 44 до 19 случаев в год). Среднее время реакции системы на потенциальные угрозы составило 154 мс, что позволило предотвратить 78 аварийных ситуаций. Уровень автоматизации мониторинга безопасности достиг 92,4%. В результате внедрения системы коэффициент травматизма снизился на 63,2% (с 15,7 до 5,8 случаев на 1000 работников).

Анализ экологических аспектов транспортной деятельности (табл. 10) свидетельствует о существенном снижении удельных выбросов CO<sub>2</sub> (на 19,2%, с 112 до 91 г/т-км), достигнутом за счет оптимизации маршрутов и повышения энергоэффективности перевозок. Удельные энергозатраты на транспортировку сократились на 14,6% (с 4,8 до 4,1 кВт-ч/т-км). Доля энергосберегающих технологий в структуре энергопотребления увеличилась с 12,4 до 26,7%.

**Таблица 9**  
Показатели безопасности транспортных потоков

**Table 9**  
Safety indicators of the traffic flows

Показатель	2020	2021	2022	2023
Количество инцидентов, случаев/год	44	36	25	19
Время реакции системы на угрозы, мс	–	–	178	154
Предотвращенные аварии, случаев/год	–	–	32	46
Уровень автоматизации мониторинга, %	18,2	45,7	68,9	92,4
Коэффициент травматизма, случаев/1000 чел.	15,7	12,3	8,6	5,8

**Таблица 10**  
Показатели экологической устойчивости транспортных потоков

Показатель	2020	2021	2022	2023
Удельные выбросы CO <sub>2</sub> , г/т-км	112	104	97	91
Удельные энергозатраты, кВт-ч/т-км	4,8	4,6	4,3	4,1
Доля энергосберегающих технологий, %	12,4	16,8	22,5	26,7
Количество экологических нарушений, случаев/год	18	14	11	7
Сокращение транспортных отходов, %	–	8,2	17,9	27,4

Количество нарушений экологических норм снизилось с 18 до 7 случаев в год. Объем отходов, связанных с эксплуатацией транспорта, сократился на 27,4%.

Для количественной оценки интеграции интеллектуальной системы с инфраструктурой горных выработок применен метод анализа охвата (табл. 11). Результаты анализа показывают, что к концу 2023 г. к системе было подключено 2562 датчика и IoT-устройства, обеспечивающих сбор данных о состоянии транспортной инфраструктуры в режиме реального времени. Средняя скорость обновления информации составила 125 мс. Уровень автоматизации транспортных процессов достиг 78,4%. Доля маршрутов, контролируемых интеллектуальной системой, увеличилась с 32,6 до 94,1%. За период 2022–2023 гг. было выполнено 28 итераций обновления аналитических моделей.

Важным фактором успешного внедрения интеллектуальной системы явилось обучение и адаптация персонала горнодобывающих предприятий. За период 2020–2023 гг. было обучено 3690 сотрудников (табл. 12), в том числе 1280 операторов горнотранспортного оборудования, 865 диспетчеров и 1545 специалистов по обслуживанию

**Таблица 11**  
Показатели интеграции систем искусственного интеллекта с инфраструктурой выработок

Показатель	2020	2021	2022	2023
Количество подключенных датчиков, шт.	486	1124	1820	2562
Скорость обновления данных, мс	–	285	196	125
Уровень автоматизации процессов, %	24,5	43,2	61,8	78,4
Доля контролируемых маршрутов, %	32,6	58,9	81,5	94,1
Количество обновлений моделей, шт./год	–	–	12	16

**Table 10**  
Indicators of environmental sustainability of the traffic flows

**Таблица 12**  
Показатели обучения и адаптации персонала

Показатель	2020	2021	2022	2023
Количество обученных сотрудников, чел.	210	760	1280	1440
Средняя продолжительность обучения, ч	62	78	89	84
Уровень удовлетворенности технологиями, %	52,4	68,7	79,2	87,6
Сокращение ошибок управления, %	–	32,5	54,8	73,2
Количество учебных тренингов, шт/год	–	28	64	92

автоматизированных систем управления. Средняя продолжительность обучения составила 84 ч. По результатам опроса уровень удовлетворенности персонала новыми технологиями достиг 87,6%. После прохождения обучения количество ошибок в управлении транспортом сократилось на 73,2%. В 2022–2023 гг. на предприятиях было проведено 156 обучающих тренингов.

Проведенный анализ рисков и барьеров (табл. 13) выявил ряд потенциальных проблем, связанных с развертыванием интеллектуальной системы в сложных условиях горной добычи. В 2022–2023 гг. зафиксировано 18 инцидентов, связанных со сбоями аппаратно-программных комплексов. Уровень финансовых рисков проекта оценивается в 15,8%, что обусловлено высокой стоимостью технологий и необходимостью постоянной модернизации инфраструктуры. На этапе запуска системы уровень сопротивления персонала изменениям достигал 42,5%, однако по мере накопления опыта эксплуатации данный показатель снизился до приемлемых 8,2%. Совокупный индекс сложности интеграции ИИ в бизнес-процессы составил 0,84. Проведенный анализ нормативно-правовой базы позволил выделить 12 положений законодательства, потенциально ограничивающих внедрение технологий ИИ в горнодобывающей отрасли.

Важным аспектом анализа является оценка синергети-

**Table 11**  
Indicators of AI systems integration with the mine infrastructure

**Таблица 13**  
Анализ рисков и барьеров внедрения искусственного интеллекта

Параметр	Значение
Количество технических сбоев, случаев/год	18
Уровень финансовых рисков, %	15,8
Сопротивление персонала изменениям, %	8,2
Индекс сложности интеграции ИИ	0,84
Количество регуляторных ограничений, шт.	12

**Table 13**  
Analysis of risks and barriers to AI implementation



ческих эффектов от комплексного применения методов ИИ на различных уровнях управления транспортной инфраструктурой. С этой целью разработана экономико-математическая модель, позволяющая количественно оценить влияние ключевых факторов на интегральный показатель эффективности транспортной системы (ITE):

$$ITE = \alpha_1 * TPR + \alpha_2 * E_I - \alpha_3 * CT - \alpha_4 * EC - \alpha_5 * RN, \quad (17)$$

где  $TPR$  – темп роста производительности труда;  $E_I$  – индекс энергоэффективности;  $CT$  – удельные транспортные издержки;  $EC$  – уровень экологической нагрузки;  $RN$  – коэффициент риска нарушений;  $\alpha_1, \dots, \alpha_5$  – параметры модели.

Оценка параметров  $\alpha_1, \dots, \alpha_5$  осуществлялась методом регрессионного анализа на основе панельных данных по пяти горнодобывающим компаниям за период 2020–2023 гг. Полученные оценки представлены в табл. 14. Из результатов следует, что наибольший вклад в рост интегральной эффективности вносит повышение производительности труда ( $\alpha_1 = 0,412$ ) и энергоэффективности ( $\alpha_2 = 0,358$ ). Напротив, рост транспортных затрат ( $\alpha_3 = -0,216$ ), экологических издержек ( $\alpha_4 = -0,187$ ) и рисков ( $\alpha_5 = -0,143$ ) оказывает сдерживающее влияние.

**Таблица 14**  
Оценки параметров модели интегральной эффективности

**Table 14**  
Assessment of parameters of the integral efficiency model

Параметр	Оценка	Статистическое отклонение	t-статистика	p-уровень
$\alpha_1$ (TPR)	0,412***	0,064	6,42	0,000
$\alpha_2$ (EI)	0,358***	0,051	7,08	0,000
$\alpha_3$ (CT)	-0,216***	0,037	-5,86	0,000
$\alpha_4$ (EC)	-0,187***	0,048	-3,92	0,001
$\alpha_5$ (RN)	-0,143*	0,062	-2,31	0,028

Примечания: зависимая переменная: ITE (интегральный показатель эффективности); количество наблюдений: 60;  $R^2 = 0,783$ ;  $F(5, 54) = 54,26$ \*\*\*; \*\*\*  $p < 0,001$ ; \*  $p < 0,05$

Разработанная модель может быть использована для прогнозирования потенциальных эффектов от масштабирования технологий ИИ в транспортной инфраструктуре горнодобывающей отрасли. В базовом сценарии, предполагающем инерционное развитие существующих трендов, интегральная эффективность увеличивается на 28,6%.

При реализации оптимистичного сценария, связанного с ускоренным внедрением ИИ, прирост эффективности может достигнуть 53,7%.

Подводя итог, можно констатировать, что применение методов адаптивной оптимизации транспортных потоков позволило существенно улучшить ключевые показатели эффективности и безопасности транспортной инфраструктуры горных предприятий. Полученные результаты создают надежную основу для дальнейшего развития интеллектуальных транспортных систем и их тиражирования в горнодобывающей отрасли.

## Заключение

Результаты исследования демонстрируют высокую эффективность применения методов адаптивной оптимизации транспортных потоков на базе ИИ в горнодобывающей отрасли. Внедрение интеллектуальной системы управления привело к сокращению среднего времени транспортировки на 21,9%, повышению пропускной способности на 18%, снижению энергозатрат на 16,2% и уменьшению количества инцидентов на 56,8%. Кластерный анализ выявил увеличение доли высоко- и среднеинтенсивных устойчивых потоков с 59 до 76%. Метод главных компонент позволил идентифицировать ключевые факторы эффективности: масштаб, равномерность и энергоэффективность потоков. Регрессионный анализ показал, что наибольший вклад в рост интегрального показателя вносят производительность труда ( $\alpha_1 = 0,412$ ) и энергоэффективность ( $\alpha_2 = 0,358$ ). Уровень автоматизации транспортных процессов достиг 78,4%, при этом обучение прошли 3690 сотрудников. Прогнозное моделирование показывает потенциал роста эффективности на 53,7% к 2030 г. при ускоренном внедрении ИИ.

Полученные результаты вносят вклад в развитие концепций цифровизации горнодобывающей промышленности и построения интеллектуальных транспортных систем. Они углубляют понимание механизмов адаптивной оптимизации сложных динамических процессов и расширяют инструментарий поддержки принятия решений в условиях неопределенности. Исследование проблематизирует традиционные подходы к управлению транспортной инфраструктурой и демонстрирует перспективность синергетической интеграции методов ИИ, облачных вычислений и промышленного интернета вещей. Разработанные модели и алгоритмы имеют высокий потенциал практического применения и могут быть адаптированы для широкого спектра индустриальных систем. Дальнейшие исследования целесообразно направить на анализ социотехнических аспектов внедрения ИИ, разработку адаптивных механизмов обеспечения кибербезопасности и изучение институциональных и регуляторных факторов цифровой трансформации горнодобывающих предприятий.

## Список литературы / References

1. Агафонов О.А., Афонина Н.В. Уточнение методов расчета грузопотоков конвейерных транспортных систем угольных шахт. *Горная промышленность*. 2023;(6):89–94. <https://doi.org/10.30686/1609-9192-2023-6-89-94>  
Agafonov O.A., Afonina N.B. Refinement of methods for calculating the material flows of conveyor transportation systems in coal mines. *Russian Mining Industry*. 2023;(6):89–94. (In Russ.) <https://doi.org/10.30686/1609-9192-2023-6-89-94>



2. Арифджанова Н.З. Применение искусственного интеллекта для оптимизации маршрутов транспорта. *Universum: технические науки*. 2023;(5-4);10–12. <https://doi.org/10.32743/UniTech.2023.110.5.15404>  
Arifjanova N.Z. Application of artificial intelligence to optimize transport routes. *Universum: Tekhnicheskie Nauki*. 2023;(5-4);10–12. (In Russ.) <https://doi.org/10.32743/UniTech.2023.110.5.15404>
3. Дмитриева В.В., Сизин П.Е. Корреляционный анализ и методы моделирования случайного грузопотока, поступающего на сборный конвейер. *Горный информационно-аналитический бюллетень*. 2018;(10):145–155. Режим доступа: [https://giab-online.ru/files/Data/2018/10/145\\_155\\_10\\_2018.pdf](https://giab-online.ru/files/Data/2018/10/145_155_10_2018.pdf) (дата обращения: 18.12.2024).  
Dmitrieva V.V., Sizin P.E. Correlation analysis and method of modeling random load flow on collecting conveyor. *Mining Informational and Analytical Bulletin*. 2018;(10):145–155. (In Russ.) Available at: [https://giab-online.ru/files/Data/2018/10/145\\_155\\_10\\_2018.pdf](https://giab-online.ru/files/Data/2018/10/145_155_10_2018.pdf) (accessed: 18.12.2024).
4. Журавлёв А.Г., Семёнкин А.В., Черепанов В.А., Глебов И.А., Чендырев М.А. Задачи развития перспективных циклично-поточных технологий для глубоких карьеров. *Горная промышленность*. 2022;(1S):53–62. <https://doi.org/10.30686/1609-9192-2022-1S-53-62>  
Zhuravlev A.G., Semenkin A.V., Cherepanov V.A., Glebov I.A., Chendyrev M.A. The purpose of developing advanced in-pit crushing and conveying technology for deep open pits. *Russian Mining Industry*. 2022;(1 Suppl.): 53–62. (In Russ.) <https://doi.org/10.30686/1609-9192-2022-1S-53-62>
5. Ильинов Н.Д., Мажитов А.М., Аллабердин А.Б., Важдяев К.В. Оптимизация схемы проветривания при увеличении производственной мощности подземного рудника. *Горная промышленность*. 2021;(6):89–93. <https://doi.org/10.30686/1609-9192-2021-6-89-93>  
Iliinov N.D., Mazhitov A.M., Allaberdin A.B., Vazhdaev K.V. Optimization of the ventilation scheme for increasing production capacity of underground mines. *Russian Mining Industry*. 2021;(6):89–93. <https://doi.org/10.30686/1609-9192-2021-6-89-93>
6. Каримов К.С. Методы искусственного интеллекта и применение их на транспорте. *Постсоветский материк*. 2023;(4):106–115. [https://doi.org/10.48137/23116412\\_2023\\_4\\_106](https://doi.org/10.48137/23116412_2023_4_106)  
Karimov K.S. Artificial intelligence methods and their application in transport. *Post-Soviet Continent*. 2023;(4):106–115. (In Russ.) [https://doi.org/10.48137/23116412\\_2023\\_4\\_106](https://doi.org/10.48137/23116412_2023_4_106)
7. Каримов К.С. Методы искусственного интеллекта и применение их на транспорте. *Постсоветский материк*. 2023;(4):106–115. [https://doi.org/10.48137/23116412\\_2023\\_4\\_106](https://doi.org/10.48137/23116412_2023_4_106)  
Karimov K.S. Artificial intelligence methods and their application in transport. *Post-Soviet Continent*. 2023;(4):106–115. (In Russ.) [https://doi.org/10.48137/23116412\\_2023\\_4\\_106](https://doi.org/10.48137/23116412_2023_4_106)
8. Кузьмин С.В., Шнайдер И.В., Кыштымов И.В. Выявление опасных зон при проходке подготовительных выработок в сложных горно-геологических условиях. *Горный журнал*. 2024;(1):45–49. <https://doi.org/10.17580/gzh.2024.01.07>  
Kuzmin S.V., Shnaider I.V., Kyshtymov I.V. Detection of hazardous zones in development headings in difficult geological conditions. *Gornyi Zhurnal*. 2024;(1):45–49. (In Russ.) <https://doi.org/10.17580/gzh.2024.01.07>
9. Лисковец А.С., Тащиенко В.П., Мешков А.А. Направления развития и совершенствования тампонажной крепи. *Горная промышленность*. 2020;(2):88–93. <https://doi.org/10.30686/1609-9192-2020-2-88-93>  
Liskovets A.S., Tatsienko V.P., Meshkov A.A. Directions of development and improvement of grouting support. *Russian Mining Industry*. 2020;(2):88–93. (In Russ.) <https://doi.org/10.30686/1609-9192-2020-2-88-93>
10. Месропян К., Житарев М.Ю. Инновационные решения на основе искусственного интеллекта для оптимизации маршрутов доставки и управления транспортными средствами. *Актуальные исследования*. 2024;(5-1):41–43. Режим доступа: <https://apni.ru/article/8374-innovatsionnie-resheniya-na-osnove-iskusstven> (дата обращения: 18.12.2024).  
Mesropyan K., Zhitarev M.Yu. Innovative solutions based on artificial intelligence to optimize delivery routes and vehicle management. *Aktualnye Issledovaniya*. 2024;(5-1):41–43. (In Russ.) Available at: <https://apni.ru/article/8374-innovatsionnie-resheniya-na-osnove-iskusstven> (accessed: 18.12.2024).
11. Насыров Р.Ш., Третьяк А.В., Неугомонов С.С., Мажитов А.М. Разработка технологии проведения и крепления горной выработки в зоне тектонически-ослабленных пород. *Горная промышленность*. 2024;(3):126–130. <https://doi.org/10.30686/1609-9192-2024-3-126-130>  
Nasyrov R.Sh., Tretyak A.V., Neugomonov S.S., Mazhitov A.M. Developing a technology of driving and supporting mine workings in tectonically weakened rock zones. *Russian Mining Industry*. 2024;(3):126–130. (In Russ.) <https://doi.org/10.30686/1609-9192-2024-3-126-130>
12. Панина О.В., Попадюк Н.К., Еремин С.Г., Токмурзин Т.М., Разумова Е.В. Применение технологий BigData для оптимизации производственных процессов в горнодобывающей промышленности России: анализ внедрения и эффективности. *Горная промышленность*. 2024;(6):178–185. <https://doi.org/10.30686/1609-9192-2024-6-178-185>  
Panina O.V., Popadyuk N.K., Eremin S.G., Tokmurzin T.M., Razumova E.V. Application of the BigData technologies to optimize production processes in the Russian mining industry: analysis of implementation and efficiency. *Russian Mining Industry*. 2024;(6):178–185. (In Russ.) <https://doi.org/10.30686/1609-9192-2024-6-178-185>

13. Турсунов Д.Г. Оптимизация транспортных потоков в городской транспортной системе с использованием имитационного моделирования. *Молодой ученый*. 2022;(14):11–16. Режим доступа: <https://moluch.ru/archive/409/89953/> (дата обращения: 18.12.2024).  
Tursunov D.G. Optimization of traffic flows in urban transport system using simulation modeling. *Molodoi Uchenyi*. 2022;(14):11–16. (In Russ.) Available at: <https://moluch.ru/archive/409/89953/> (accessed: 18.12.2024).
14. Федотенко В.С., Власов А.В., Кливер С.Я., Шадронов А.Г. К обоснованию условий и параметров формирования горнотехнических систем при строительстве и эксплуатации комплекса циклично-поточной геотехнологии в глубоких карьерах. *Горная промышленность*. 2020;(5):102–107. <https://doi.org/10.30686/1609-9192-2020-5-102-107>  
Fedotenko V.S., Vlasov A.V., Kliver S.Ya., Shadrinov A.G. Justification of Conditions and Parameters for Designing of Mining Systems in Construction and Operation of Complex Conveyor Ore Transportation in Deep Open-Cast Mines. *Russian Mining Industry*. 2020;(5):102–107. (In Russ.) <https://doi.org/10.30686/1609-9192-2020-5-102-107>
15. Федотов И.С. Применение методов глубокого обучения для анализа больших данных. *Вестник науки*. 2024;4(8):196–198. Режим доступа: <https://www.вестник-науки.рф/article/17070> (дата обращения: 18.12.2024).  
Fedotov I.S. Application of deep learning methods for big data analysis. *Vestnik Nauki*. 2024;4(8):196–198. (In Russ.) Available at: <https://www.вестник-науки.рф/article/17070> (accessed: 18.12.2024).

**Информация об авторах**

**Кадырова Гульназ Маннуровна** – доктор экономических наук, декан факультета «Высшая школа управления», Финансовый университет при Правительстве Российской Федерации, г Москва, Российская Федерация; e-mail: [GMKadyirova@fa.ru](mailto:GMKadyirova@fa.ru)

**Красюкова Наталья Львовна** – доктор экономических наук, профессор кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: [NLKrasjukova@fa.ru](mailto:NLKrasjukova@fa.ru)

**Рождественская Ирина Андреевна** – доктор экономических наук, профессор кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: [IRozhdestvenskaya@fa.ru](mailto:IRozhdestvenskaya@fa.ru)

**Токмурзин Тимур Маратович** – кандидат экономических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: [ttokmurzin@fa.ru](mailto:ttokmurzin@fa.ru)

**Воронова Екатерина Игоревна** – ассистент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: [EIShayuk@fa.ru](mailto:EIShayuk@fa.ru)

**Информация о статье**

Поступила в редакцию: 25.12.2024

Поступила после рецензирования: 22.01.2025

Принята к публикации: 23.01.2025

**Information about the authors**

**Gulnaz M. Kadyrova** – Dr. Sci. (Econ.), Dean of the Faculty of Higher School of Management, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: [GMKadyirova@fa.ru](mailto:GMKadyirova@fa.ru)

**Natalya L. Krasjukova** – Dr. Sci. (Econ.), Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: [NLKrasjukova@fa.ru](mailto:NLKrasjukova@fa.ru)

**Irina A. Rozhdestvenskaya** – Dr. Sci. (Econ.), Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: [IRozhdestvenskaya@fa.ru](mailto:IRozhdestvenskaya@fa.ru)

**Timur M. Tokmurzin** – Cand. Sci. (Econ.), Associate Professor, Department of State and Municipal Administration, Financial University, Moscow, Russian Federation; e-mail: [ttokmurzin@fa.ru](mailto:ttokmurzin@fa.ru)

**Ekaterina I. Voronova** – Assistant at the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: [EIShayuk@fa.ru](mailto:EIShayuk@fa.ru)

**Article info**

Received: 25.12.2024

Revised: 22.01.2025

Accepted: 23.01.2025