

МЕТОД ПОСТРОЕНИЯ АВТОМАТИЗИРОВАННОЙ СИСТЕМЫ ДЛЯ ОЦЕНКИ ЭФФЕКТИВНОСТИ ФУНКЦИОНИРОВАНИЯ ГОРНЫХ МАШИН НА ОСНОВЕ МЕТОДА ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Р.Н. Сафиуллин¹, С.А. Парра¹, Р.Р. Сафиуллин¹, М.С. Присяжнюк², Л.А. Симонова³

¹ Санкт-Петербургский горный университет императрицы Екатерины II,
Санкт-Петербург, Россия, e-mail: zuny1503@gmail.com

² Комитет Ленинградской области по транспорту, Санкт-Петербург, Россия

³ Казанский федеральный университет, Набережночелнинский филиал, Набережные Челны, Россия

Аннотация: Предложен инновационный метод создания автоматизированной системы оценки эффективности горных машин на основе искусственного интеллекта. В отличие от традиционных методов, ограниченных статичными показателями и одномерным анализом, предложенная система интегрирует технические, эксплуатационные факторы, а также факторы безопасности, объединяя количественные данные (расход топлива, время цикла) с качественными лингвистическими параметрами («низкая», «средняя», «высокая» эффективность). Ключевым отличием является применение модели «черного ящика», упрощающей анализ за счет фокусировки на входных и выходных параметрах, и нечеткой логики, обеспечивающей интерпретируемость результатов через экспертные правила. Это позволяет системе динамически адаптироваться к изменениям условий эксплуатации и обрабатывать неполные или зашумленные данные в реальном времени. Новизна работы заключается в синтезе данных от датчиков, GPS и исторических записей с использованием вывода Мамдани, что обеспечивает целостную оценку, учитывающую как производительность, так и безопасность. Система преодолевает ограничения существующих решений, которые зачастую игнорируют контекстуальные факторы (например, вариативность времени простоя) и не справляются с лингвистической неопределенностью. Модульная архитектура позволяет калибровать модель на основе исторических данных и оптимизировать правила с помощью машинного обучения, что повышает ее точность в долгосрочной перспективе. Актуальность исследования обусловлена растущей потребностью горнодобывающей отрасли в ресурсосберегающих технологиях, способных снижать эксплуатационные затраты и минимизировать экологическое воздействие. Предложенный метод открывает возможности для автоматизации принятия решений, оптимизации логистики и прогнозирования рисков, демонстрируя потенциал для внедрения в условиях цифровой трансформации горного производства.

Ключевые слова: искусственный интеллект, эффективность горных машин, автоматизированная система, нечеткая логика, оптимизация ресурсов, модель «черного ящика», показатели.

Для цитирования: Сафиуллин Р. Н., Парра С. А., Сафиуллин Р. Р., Присяжнюк М. С., Симонова Л. А. Метод построения автоматизированной системы для оценки эффективности функционирования горных машин на основе метода искусственного интеллекта // Горный информационно-аналитический бюллетень. – 2026. – № 3. – С. 115–135. DOI: 10.25018/0236_1493_2026_3_0_115.

AI-based automated system design for efficiency evaluation of performance of mining machines

P.N. Safiullin¹, Z.A. Parra¹, R.R. Safiullin¹, M.S. Prisyazhnyuk², L.A. Simonova³

¹ Empress Catherine II Saint-Petersburg Mining University, Saint-Petersburg, Russia

² Leningrad Region Transport Committee, Saint-Petersburg, Russia

³ Naberezhnye Chelny (Institute) Branch of Kazan Federal University, Naberezhnye Chelny, Russia

Abstract: The article puts forward an innovative method of designing an automated system of mining machine efficiency evaluation based on artificial intelligence. As against conventional methods limited by static indicators and one-dimensional analysis, the proposed system integrates the factors of technology, operation and safety, and unites the quantitative data (fuel consumption, cycle time) with the qualitative linguistic parameters (low/medium/high efficiency). The key difference is the use of the black box model, which simplifies the analysis by focusing on input and output parameters, and fuzzy logic, which ensures interpretability of results through expert rules. This enables the system to adapt fluently to variable operating conditions, and to process incomplete or noisy data in real time. The novelty of the approach is the synthesis of sensor data, GPS and historical sources using the Mamdani algorithm, which ensures an integral estimate including both safety and productivity. The system overcomes constraints of existing solutions which often neglect contextual factors (for instance, variability of downtime) and prove unable to handle linguistic uncertainty. The modular architecture allows calibrating the model on the basis of historical sources and optimizing the rules using machine learning, which improves the model accuracy in the long term. The relevance of the research is conditioned by the growing demand of the mining industry for resource-saving technologies capable of reducing operational costs and minimizing ecological impacts. The proposed method opens up new opportunities for decision-making automation, logistic optimization and risk prediction, and offers potential for introduction in the conditions of digital transformation of mining practices.

Key words: artificial intelligence, efficiency of mining machines, automated system, fuzzy logic, optimization of resources, black box model, indicators.

For citation: Safiullin P. N., Parra Z. A., Safiullin R. R., Prisyazhnyuk M. S., Simonova L. A. AI-based automated system design for efficiency evaluation of performance of mining machines. *MIAB. Mining Inf. Anal. Bull.* 2026;(3):115-135. [In Russ]. DOI: 10.25018/0236_1493_2026_3_0_115.

Введение

Транспортные системы служат основой экономического роста. Однако неэффективное распределение ресурсов ведет к увеличению затрат, задержкам и наносит вред окружающей среде.

Эффективность эксплуатации транспортных средств имеет решающее значение для снижения выбросов и оптимизации логистики. Традиционные методы оценки, основанные на ручном анализе

и статических показателей, не позволяют адаптироваться к реальному времени, требуют много времени на обработку и чреваты ошибками. Искусственный интеллект предлагает динамические решения на основе предиктивной аналитики и распознавания образов и позволяет проводить автоматизированную оценку эффективности в режиме реального времени, улучшая процесс принятия решений в управлении транспортом.

Традиционные показатели, такие как расход топлива на километр или средняя грузоподъемность, часто не учитывают контекстуальные факторы, такие как изменчивость времени простоя или возраст транспортного средства [1, 2]. Кроме того, такие термины, как «высокая эффективность» или «низкая стоимость», по своей сути являются расплывчатыми, поэтому требуются методы, учитывающие двусмысленность.

Области применения искусственного интеллекта (ИИ) в транспорте включают автономные транспортные средства, прогнозирование спроса, управление пробками, оптимизацию транспортных потоков в карьерах, прогнозирование производительности, оптимизацию диспетчеризации транспортных средств и др. [3]. Однако для оценки эффективности требуется агрегирование разрозненных потоков данных, поэтому необходимы системы, способные работать с неточностями. Нечеткая логика с ее способностью моделировать градуированные истинностные значения оказывается надежным инструментом для таких условий.

Искусственный интеллект изменил транспортную сферу благодаря предиктивной аналитике, автономным транспортным средствам, системам управления движением, возможности управлять жизненным циклом горнодобывающих компаний, оптимизировать транспортные потоки на открытых и подземных разработках, прогнозировать производительность самосвалов [4, 5], принимать оптимальные решения по обработке материалов на открытых разработках [6, 7]. Модели машинного обучения (ML – Machine Learning) анализируют большие массивы данных для оптимизации маршрутов, снижения расхода топлива, улучшения управления транспортным потоком, прогнозирования моделей для различных приложений в горнодобыва-

ющей промышленности [8–10]. С помощью методов глубокого обучения улучшают обнаружение объектов при автономном вождении, а при обучении с подкреплением оптимизируют управление дорожными сигналами, логистическими маршрутами и пр. [11, 12].

В работе Г.М. Кадыровой и др. [13] использован комплексный подход, сочетающий методы машинного обучения, имитационного моделирования и многокритериальной оптимизации, для разработки и оценки методов адаптивной оптимизации транспортных потоков в подземных выработках, способствующих повышению экономической эффективности и экологической устойчивости горнодобывающих предприятий [14]. Н.В. Цхададзе и др. [15] создали концептуальную модель и архитектуру интеллектуальной системы управления жизненным циклом горного предприятия, различные методы и алгоритмы для оптимизации основных процессов горного производства с учетом принципов циркулярной экономики, а также разработали прототип системы, который был опробован на данных реальных горных предприятий в России. С другой стороны, С. Fan и др. [5] предложили два алгоритма ансамблевого обучения на основе деревьев, включая случайный лес (RF – random forest) и регрессию с градиентным усилением (GBR – gradient boosting regression), в сочетании с моделированием гауссовой смеси (GMM – Gaussian mixture modelling) для обучения моделей прогнозирования производительности самосвалов.

Модель «черного ящика» в основном используется в сложных промышленных системах, для прогнозирования и анализа дорожного движения, хотя имеет и другие применения в инженерной сфере [16]. В работе I. Abdurashid и др. [17] использовались четыре модели, основанные на машинном обуче-

нии «черного ящика», — искусственная нейронная сеть (ANN — artificial neural network), векторная машина поддержки (SVM — support vector machine), случайный лес (RF — random forest) и экстремальное градиентное усиление (XGBoost — extreme gradient boosting). Эти модели применялись для улучшения проактивного управления безопасностью автомобильных перевозок, что критически важно для глобальных сетей цепочек поставок. В.Б. Коновалов и др. [18] создали устройство для своевременной регистрации и мониторинга технического состояния транспортных средств, а также психофизиологического состояния водителей в процессе расследования дорожно-транспортных происшествий.

Нечеткая логика, введенная L.A. Zadeh (1965), представляет собой математическую основу для моделирования неточных понятий с помощью функций принадлежности и систем, основанных на правилах. Ее применение в транспорте включает оптимизацию маршрутов [19] и планирование технического обслуживания [20], планирование перевозок [21] и оценку рисков [22]. W. Meethom и N. Koohathongsumrit [23] разработали концепцию асимметричной системы поддержки принятия решений на основе нечетких чисел (FAHP — Fuzzy Analytic Hierarchy Process, нечеткий аналитический иерархический процесс) и многослойного объектного программирования «ноль-один» для ранжирования маршрутов распределения. N. Koohathongsumrit и др. [24] предлагают новый метод принятия решений, объединяющий метод наилучшего-худшего (BWM — Best-Worst Method), нечеткую иерархическую оценку рисков (FHRA — Fuzzy Hierarchical Risk Assessment) и оценку аддитивного соотношения (ARAS — additive ratio assessment). M. Ilyas и др. [25] представляют новый подход к повы-

шению эффективности транспортировки сырой нефти путем интеграции нечеткой логики и метода TOPSIS (Technique for Order of Preference by Similarity to Ideal Solution). A. Pálková и др. [26] предлагают использовать нечеткую логику для оценки заявок на перевозку и принятия обоснованных решений для повышения качества обслуживания и рентабельности. E. A. Thompson и др. [27] объединили нечеткий метод Дельфи (FDM — Fuzzy Delphi Method) и метод наилучшего-худшего (BWM) для оценки 17 факторов, определяющих устойчивость грузовых перевозок в Африке. В работе M. Baban и др. [28] нечеткая логика была использована для планирования политики технического обслуживания шлифовальных кругов на автоматизированных шлифовальных линиях. B. Selvalakshmi и др. [29] использовали систему нечеткой логики для прогнозирования технического обслуживания, включая предварительную обработку данных, выбор признаков, генерацию нечетких правил и оценку модели.

Однако лишь немногие исследования посвящены комплексной оценке эффективности транспортных средств путем сочетания этих подходов [30, 31].

Чтобы восполнить этот недостаток, в статье предлагается гибридная методика, сочетающая метод «черного ящика», который рассматривает транспортную систему как непонятный объект с измеримыми входами и выходами, и нечеткую логику, которая переводит качественные экспертные знания в количественные правила для принятия решений в условиях неопределенности.

Методы и материалы

Нечеткая логика выбрана в качестве основного метода для оценки эффективности горных машин ввиду ее способности работать с неопределенностью, характерной для эксплуатационных дан-

ных (например, неточность датчиков, субъективность экспертных оценок).

В отличие от бинарной логики, нечеткая логика позволяет моделировать лингвистические термины («низкая», «средняя», «высокая» эффективность) и обрабатывать их с помощью градуированных функций принадлежности, что критично для комплексной оценки, объединяющей количественные и качественные факторы.

В формальном смысле нечеткое множество A определяется функцией принадлежности, представленной $A: U [0, 1]$, которая переводит элемент u в степень его принадлежности; другими словами, $A(u)$ — это степень принадлежности u к A , если задана вселенная дискурса U и u как ее общая составляющая. Если A — регулярное множество, то результат функции принадлежности $A(u)$ может быть только 1 или 0.

Согласно Chadi [32], многие определения и характеристики нечетких множеств также являются прямым продолжением определений и характеристик

обычных множеств. Вот некоторые примеры:

1) нечеткое множество A пусто тогда и только тогда, когда $\mu A(u) = 0, \forall u \in U$;

2) два нечетких множества A и B равны тогда и только тогда, когда $\mu A(u) = \mu B(u), \forall u \in U$;

3) дополнение A , обозначаемое через \bar{A} , определяется $\mu \bar{A}(u) = 1 - \mu A(u)$;

4) нечеткое множество A содержится в B тогда и только тогда, когда $\mu A(u) \leq \mu B(u), \forall u \in U$;

5) объединением нечетких множеств A и B является нечеткое множество C , определяемое $\mu C(u) = \max(\mu A(u), \mu B(u)), u \in U$;

6) пересечением нечетких множеств A и B является нечеткое множество C , определяемое $\mu C(u) = \min(\mu A(u), \mu B(u)), u \in U$.

При построении системы нечеткой логики для каждой переменной необходимо определить множество функций принадлежности, которые определяют степень принадлежности значения пе-

Таблица 1

Функции принадлежности [составлено авторами]
Membership functions [compiled by the authors]

Функции принадлежности	Описание и формула
Треугольная	определяется тремя параметрами: a, b и c , где a и c — основания треугольника, b — вершина $\mu(x) = 0$ если $x \leq a$ (1) $\mu(x) = \{(x - a)/(b - a)$ если $a < x < b\}$ (2) $\mu(x) = \{ \frac{c - x}{c - b}$ если $b < x < c\}$ (3) $\mu(x) = 0$ если $x \geq c$ (4)
Трапецевидная	определяется четырьмя параметрами: a, b, c и d , где a и d — нижнее и верхнее основания, b и c — границы плато $\mu(x) = \{0$ если $x \leq a$ (5) $\mu(x) = \{ \frac{x - a}{b - a}$ если $a < x \leq b\}$ (6) $\mu(x) = \{1$ если $b < x \leq c$ (7) $\mu(x) = \{ \frac{d - x}{d - c}$ если $c < x < d\}$ (8) $\mu(x) = \{0$ если $x \geq d$ (9)

ременной к группе по отношению к совокупности рассуждений.

В системе определены следующие лингвистические переменные, отражающие ключевые показатели эффективности (KPI):

- входные переменные, например: расход топлива: «низкий» (5–12 л/км), «средний» (10–20 л/км), «высокий» (18–30 л/км);

- коэффициент использования грузоподъемности: «низкий» (0–50%), «средний» (40–80%), «высокий» (70–100%);

- время простоя: «низкое» (0–4 ч/сут), «среднее» (3–9 ч/сут), «высокое» (8–24 ч/сут);

- выходная переменная — эффективность: «низкая» (0–50%), «средняя» (30–70%), «высокая» (60–100%);

- функции принадлежности: для каждой переменной использованы треугольные и трапециевидные функции принадлежности, оптимальные для моделирования плавных переходов между лингвистическими терминами (табл. 1).

Далее, определяются утверждения или правила, связывающие функции принадлежности с результатом с помощью утверждений ЕСЛИ-ТО. Правила взвешиваются по их важности, а затем выполняется математическая оценка правил и объединение результатов. Агрегация используется для оценки каждого правила, а дефаззификация — для оценки результирующей функции в виде четкого числа.

На этапе дефаззификации применяется метод центроида для получения комплексных оценок эффективности в диапазоне от 0 до 100%:

$$Y_d = \frac{\sum_{l=1}^R \delta_l \mu_{B_l(\delta_l)}}{\sum_{l=1}^R \mu_{B_l(\delta_l)}}, \quad (9)$$

где δ_l — центр тяжести нечеткого мно-

жества выхода B_l l -го правила; R — количество правил.

Результаты и обсуждение

Автоматизированная система, основанная на методах искусственного интеллекта, предназначена для мониторинга и оценки эффективности горных машин. Ее ключевые компоненты решают следующие задачи: сбор данных с помощью датчиков, GPS и из исторических баз данных, что позволяет получать показатели в реальном времени. Обработка данных выявляет аномалии и нормализует данные для обеспечения их качества. Система нечетких выводов преобразует четкие входные данные в нечеткие множества, применяет правила и дефаззифицирует выходные данные в баллы эффективности.

Система состоит из блоков, представленных на рис. 1.

Данные собираются с помощью GPS-трекеров, бортовых датчиков и журналов технического обслуживания, что обеспечивает мониторинг в реальном времени.

Черный ящик транспортной системы абстрагируется на входы и выходы без моделирования внутренней механики (см. рис. 2).

В работе учитываются следующие показатели: расход топлива, рабочая скорость, время простоя, время цикла, часы производительности, коэффициент использования пробега, коэффициент использования грузоподъемности. В выводе Мамдани они представлены в виде лингвистических переменных. Как правило, для каждой входной переменной используется более одного Мамдани-вывода (МВ), поскольку один МВ может определить только одно нечеткое множество [32]. Далее были определены функции принадлежности. В статье использовались следующие лингвистические переменные: «низкий» (Н), «сред-



Рис. 1. Функциональная архитектура адаптивной автоматизированной системы оценки эффективности горных машин [составлено авторами]

Fig. 1. Functional architecture of an adaptive automated system for assessing the effectiveness of mining machines [compiled by the authors]

ний) (С), «высокий» (В) и «короткий» (К), «средний» (С) и «долгий» (Д) (см. табл. 2).

Лингвистические переменные (приоритет, близость) представлены гауссовыми функциями принадлежности (см. рис. 3–12).

Анализ рисунков функций принадлежности (см. рис. 3–12) показывает,

что для большинства входных параметров (например, расход топлива, коэффициент использования грузоподъемности) зоны «низкого», «среднего» и «высокого» значений частично перекрываются. Это является ключевым преимуществом нечеткой логики, так как позволяет плавно (smooth) переходить от одного лингвистического термина к другому,

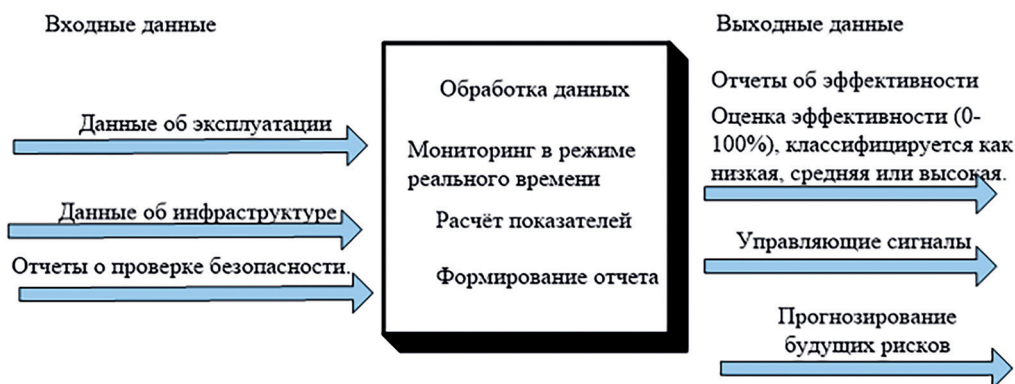


Рис. 2. Модель функционирования «черного ящика» для оценки эффективности горных машин [составлено авторами]

Fig. 2. Black box model for assessing the effectiveness of mining machines [compiled by the authors]

Таблица 2

Диапазон уровней показателей [составлено авторами]
Range of indicator levels [compiled by the authors]

Показатели	Диапазон уровней			Функция принадлежности
Расход топлива (л/км)	низкий [5; 12]	средний [10; 20]	высокий [18; 30]	(трапециевидная: 5, 5, 8, 12) (треугольная: 10, 15, 20) (трапециевидная: 18, 22, 25, 30, 30).
Время цикла (мин)	короткое [15; 90]	среднее [60 – 120]	долгое [105 – 180]	(трапециевидная: 15, 15, 45, 90) (треугольная: 60, 90, 120) (трапециевидная: 105, 135, 180, 180)
Коэффициент использования грузоподъемности	низкий [0; 50]	средний [40; 0,80]	высокий [70 – 100]	(трапециевидная: 0; 0; 0,30; 0,50) (треугольная: 0,40; 0,60; 0,80) (трапециевидная: 0,70; 0,90; 1,00; 1,00)
Коэффициент использования пробега	низкий [0; 0,60]	средний (0,50; 0,90)	высокий (0,80 – 1,00)	(трапециевидная: 0; 0; 0,40; 0,60) (треугольная: 0,50; 0,70; 0,90) (трапециевидная: 0,80; 0,95; 1,00; 1,00)
Время простоя (ч/сут)	низкое [0; 4]	среднее [3; 9]	высокое [8; 24]	(трапециевидная: 0; 0; 2; 4) (треугольная: 3; 6; 9) (трапециевидная: 8; 12; 24; 24)
Часы производительности (ч/день)	низкие [0; 12]	средние [10; 18]	высокие [16; 24]	(трапециевидная: 0; 0; 8; 12) (треугольная: 10; 14; 18) (трапециевидная: 16; 20; 24; 24)
Эксплуатационная скорость (км/ч)	низкая [5; 15]	средняя [12; 28]	высокая [25 – 40]	(трапециевидная: 5; 5; 10; 15) (треугольная: 12; 20; 28) (трапециевидная: 25; 30; 40; 40)
Количество дорожно-транспортных происшествий (аварии/месяц)	низкое [0; 3]	среднее [2; 6]	высокое [>5]	(трапециевидная: [0, 0, 1, 3]) (треугольная: [2, 4, 6]) (трапециевидная: [5, 7, 10, 10])
Количество раненых (раненых/месяц)	низкое [0; 3]	среднее [2; 6]	высокое [5; 10]	(трапециевидная: [0, 0, 1, 3]) (треугольная: [2, 4, 6]) (трапециевидная: [5, 7, 10, 10])
Эффективность использования транспорта (%)	низкая [0 – 50]	средняя [30 – 70]	высокая [60 – 100]	(трапециевидная: 0, 0, 30, 50) (треугольная: 40, 60, 80) (трапециевидная: 70, 90, 100, 100)

адекватно моделируя неопределенность и размытость реальных эксплуатационных данных. Например, значение расхода топлива в 19 л/км одновременно с определенной степенью принадлежности относится как к категории «высокий» (по функции на рис. 3), так и к категории «средний». Такая модель гораздо точнее бинарной логики отражает экспертные оценки.

В данном исследовании для отражения оценок лиц, принимающих решения, использовались треугольные и трапециевидные нечеткие значения. Для каждого нечеткого множества определяется функция принадлежности, которая определяет степень принадлежности конкретного значения к этому множеству. После этого определяется база правил в качестве контроллера нечеткой ло-

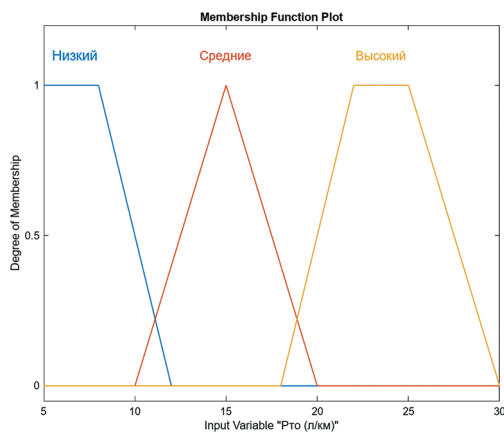


Рис. 3. График функции принадлежности для расхода топлива [составлено авторами]
 Fig. 3. Membership function plot for fuel consumption [compiled by the authors]




Рис. 4. График функции принадлежности для эксплуатационной скорости [составлено авторами]
 Fig. 4. Membership function plot for the operational speed [compiled by the authors]

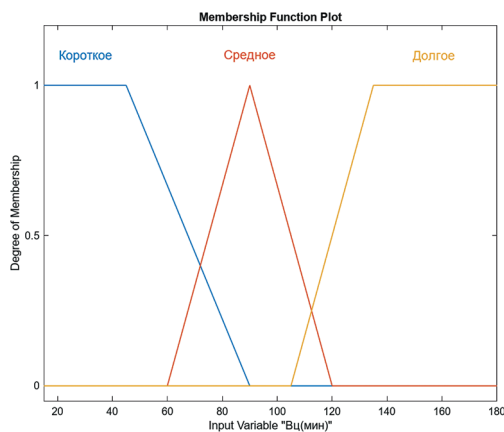


Рис. 5. График функции принадлежности для времени цикла [составлено авторами]
 Fig. 5. Membership function plot for cycle time [compiled by the authors]

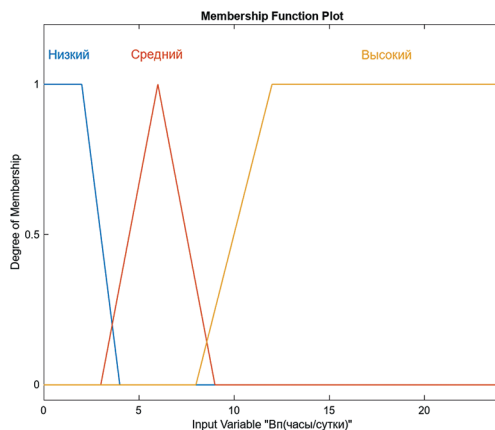


Рис. 6. График функции принадлежности для времени простоя [составлено авторами]
 Fig. 6. Membership function plot for idle time [compiled by the authors]

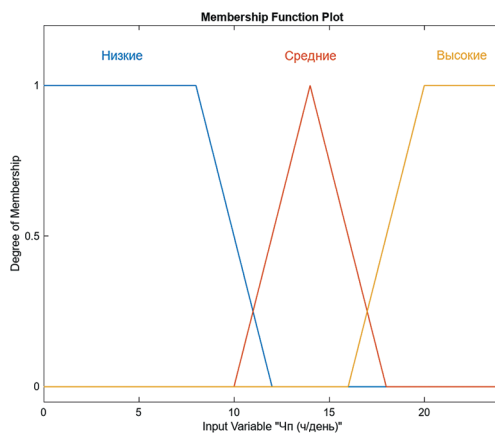


Рис. 7. График функции принадлежности для часов производительности [составлено авторами]
 Fig. 7. Membership function plot for performance hours [compiled by the authors]




Рис. 8. График функции принадлежности для коэффициента использования пробега [составлено авторами]
 Fig. 8. Membership function plot for mileage utilisation coefficient [compiled by the authors]




Рис. 9. График функции принадлежности для коэффициента использования грузоподъемности [составлено авторами]
 Fig. 9. Membership function plot for the load capacity utilisation coefficient [compiled by the authors]

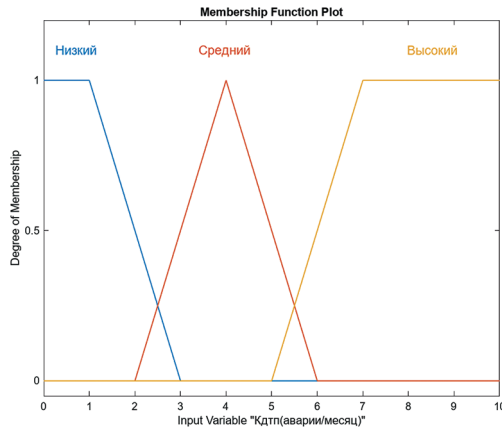


Рис. 10. График функции принадлежности для количества ДТП [составлено авторами]
 Fig. 10. Membership function plot for the number of road accidents [compiled by the authors]

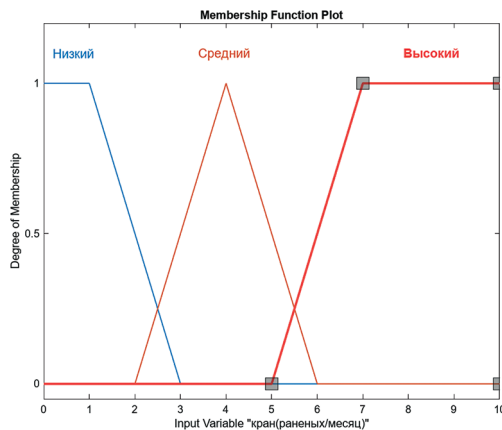


Рис. 11. График функции принадлежности для количества раненых [составлено авторами]
 Fig. 11. Membership function plot for the number of injured persons [compiled by the authors]




Рис. 12. График функции принадлежности для эффективности использования транспорта [составлено авторами]
 Fig. 12. Membership function plot for transport efficiency [compiled by the authors]

гики, предложенная в 1974 г. Мамдани. В процессе нечеткого вывода используются параллельные правила вида ЕСЛИ-ТО для проецирования входных переменных в пространство выходных [33]. На рис. 13 представлена схема, показывающая процессы, связанные с разработкой нечеткого вывода Мамдани для оценки эффективности транспортного средства.

Нечеткая система выводов (FIS – Fuzzy inference system) типа Мамдани состоит из этапов, представленных на рис. 13.

Показатели оцениваются в зависимости от степени их важности (табл. 3).

Таким образом, горные машины, демонстрирующие наивысшие значения интегрального показателя эффективности, определяются системой как наи-

Таблица 3

Матрица приоритетных правил [составлено авторами]
Matrix of priority rules [compiled by the authors]

Расход топлива	Эксплуатационная скорость (км/ч)	Время цикла (мин)	Время простоя (мин)	Часы производительности (ч/день)	Коэффициент использования пробега	Коэффициент использования грузоподъемности (%)	Количество дорожно-транспортных происшествий (аварии/месяц)	Количество раненых (раненых/месяц)	Результаты
высокий	низкая	долгое	высокое	короткие	низкий	низкий	высокое	высокое	эффективность низкая
средний	высокая	среднее	низкое	высокие	высокий	высокий	низкое	низкое	эффективность высокая
низкий	средняя	короткое	среднее	средние	средний	средний	среднее	среднее	эффективность средняя

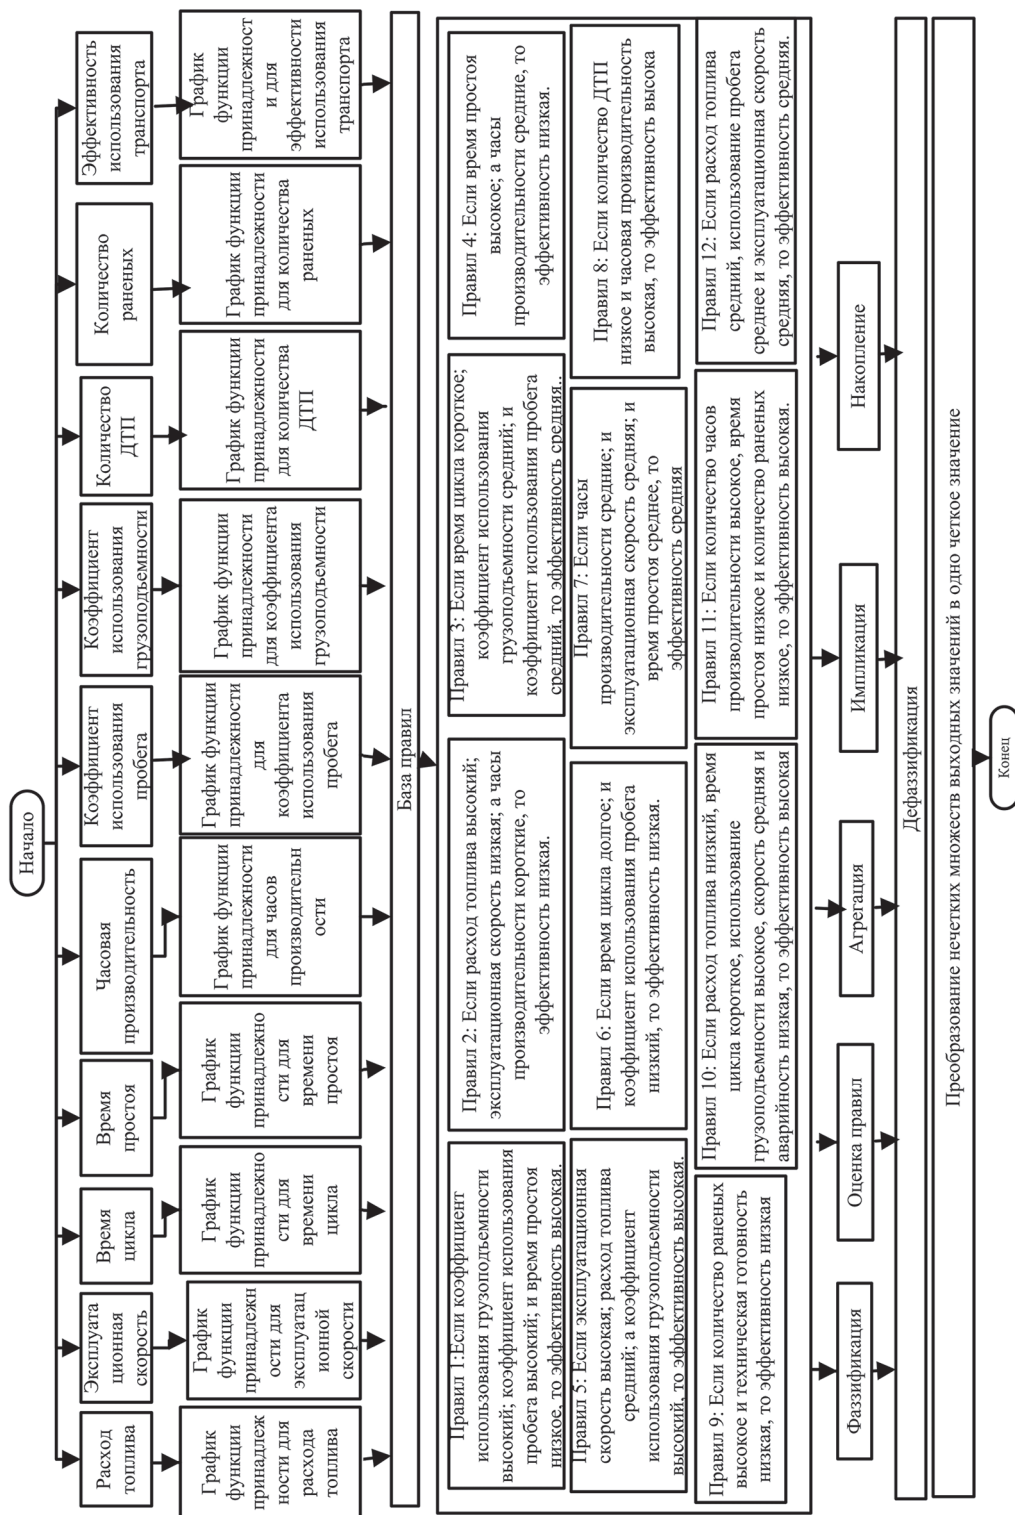


Рис. 13. Архитектура построения автоматизированной системы оценки эффективности горных машин на основе нечеткой логики [составлено авторами]
 Fig. 13. Architecture of building an automated system for evaluating the effectiveness of mining machines based on fuzzy logic [compiled by the authors]

более оптимальные для эксплуатации. Этот подход имеет ряд преимуществ, таких как адаптация системы к изменениям условий эксплуатации (например, внедрение новых машин, изменение маршрутов, новое оборудование) за счет автоматической калибровки функций принадлежности и оптимизации правил на основе обновляемых данных. Это достигается за счет интеграции алгоритмов машинного обучения, которые пересчитывают веса входных параметров и корректируют лингвистические правила, сохраняя актуальность модели в долгосрочной перспективе. Использование экспертных знаний при формировании правил системы повышает прозрачность принимаемых решений для специалистов. Еще одним преимуществом системы является устойчивость к неполным или зашумленным данным (например, временные погрешности датчиков), ко-

торые обрабатываются за счет аппроксимации значений на основе функций принадлежности и экспертных правил.

Рекомендуется откалибровать диапазоны нечетких множеств с помощью исторических данных об эксплуатации горной машины, определить приоритеты правил, отражающих критические операционные политики (например, безопасность против производительности), и интегрировать модуль машинного обучения для автоматической оптимизации правил.

В рамках апробации нами были использованы данные с карьерных самосвалов БелАЗ-75145 и гусеничные экскаваторы ЭКГ-20К на одном из железорудных карьеров, собираемые в течение 3 месяцев. Выборка включала данные с бортовых датчиков и GPS-трекеров по 85 машинам (60 самосвалов и 25 экскаваторов), что в совокупности соста-

Таблица 4

Сравнительная характеристика подходов к оценке эффективности горной техники [составлено авторами]
Comparative characteristics of approaches to assessing the efficiency of mining equipment [compiled by the authors]

Метрик / Метод	Традиционный (KPI) [10]	Random Forest (RF) [5, 17]	Наша модель (нечеткая модель – FIS)
Коэффициент корреляции (R^2) с экспертными оценками	0,65	0,82	0,89
Среднеквадратичная ошибка (RMSE)	1,45	0,98	0,72
Устойчивость к шуму (падение R^2 при 10% шума в данных)	-12%	-18%	-5%
Интерпретируемость	высокая	низкая («черный ящик»)	высокая (понятные правила «ЕСЛИ-ТО»)
Учет лингвистической неопределенности	нет	частично (через категоризацию)	да (через нечеткую логику)
Учет факторов безопасности	как правило, отсутствует	редко	встроена в модель
Адаптивность к изменению условий	низкая	высокая (требует переобучения)	средняя/высокая (через калибровку правил и ML-модуль)
MAPE на тестовой выборке	22,3%	11,7%	9,4%

вило более 5000 машин-смен. Система получала входные данные в режиме реального времени: расход топлива — через CAN-шины; координаты и скорость — с GPS-трекеров; время цикла и простоев — из диспетчерской системы; данные о ДТП и техническом состоянии — из журналов ТО.

На основе этих данных ежедневно рассчитывался интегральный показатель эффективности (в %) с использованием нечеткого вывода Мамдани.

Для сравнения были выбраны традиционный метод на основе KPI для расчета эффективности как средневзвешенного значения нормированных показателей (расход топлива, коэффициент использования грузоподъемности, время простоя), модель Random Forest (RF), а также алгоритм машинного обучения «черного ящика» [8, 23] и предлагаемая нечеткая модель (FIS).

В качестве «эталоны истины» использовались ежемесячные комплексные оценки эффективности, даваемые бригадирами и главным механиком карьера на основе их многолетнего опыта (по

10-балльной шкале). Результаты сравнения представлены в табл. 4.

Нечеткая модель (FIS) показала самую высокую корреляцию с экспертными оценками и наименьшую ошибку. Это подтверждает, что гибридный подход, объединяющий количественные данные и качественные экспертные правила, позволяет точнее уловить (captured) нюансы реальной эксплуатации. Модель FIS продемонстрировала наибольшую устойчивость к зашумленным данным (например, к случайным сбоям датчиков), что критически важно в суровых условиях карьера. Это прямое следствие использования функций принадлежности, которые «сглаживают» резкие выбросы.

Для машин с аномально высокими временами простоя (8 ч/сут) и средним расходом топлива (15 л/км) система выделила 12 единиц техники с эффективностью ниже 45%. Последующая диагностика показала:

- у 7 машин — повышенный расход топлива при низкой загрузке (коэффициент использования грузоподъемности < 40%);




Рис. 14. Относительное влияние входных переменных на итоговую оценку эффективности [составлено авторами]

Fig. 14. Relative influence of input variables on the final performance assessment [compiled by the authors]

- у 3 — частые простои (> 10 ч/сут), вызванные неоптимальной маршрутизацией;

- у 2 — повышенный риск аварийности (более 4 ДТП за месяц).

Система сгенерировала пояснение на основе правил: ЕСЛИ (Время простоя = Высокое) И (Расход топлива = Средний), ТО (Эффективность = Низкая). Это полностью соответствовало экспертной оценке, которая связала простой с частыми поломками, что не было бы очевидно при анализе лишь отдельных KPI.

Эти данные согласуются с выводами С. Fan и др. [8], где дальность перевозки также оказалась ключевым фактором, но в отличие от их «черного ящика», наша система позволяет объяснить, почему именно этот параметр оказал наибольшее влияние — через активированные экспертные правила.

На рис. 14 приведена диаграмма важности факторов, полученная на основе анализа весов нечетких правил и частоты их срабатывания:

Обсуждение результатов позволяет заключить, что основное преимущество предложенной системы заключается в ее сбалансированности: она сочетает высокую точность, сопоставимую с моделями машинного обучения, с прозрачностью и устойчивостью, присущими системам на основе знаний.

Выводы

В данном исследовании предлагается инновационная автоматизированная система на основе искусственного интеллекта для оценки эффективности эксплуатации горных машин, объединяющая в единую структуру технические, эксплуатационные факторы и безопасность. Используя гибридную модель нечеткой логики, система решает проблему сложности и неоднозначности, присущую горным операциям, объединяя

количественные данные (например, расход топлива, время цикла, время простоя) с качественными лингвистическими терминами (например, «низкая», «средняя» или «высокая» эффективность). Подход «черного ящика» упрощает моделирование системы, фокусируясь на критических входах и выходах, сохраняя при этом интерпретируемость с помощью правил, определяемых экспертами.

Основной результат этой работы заключается в том, что система синтезирует данные с датчиков реального времени, GPS-трекинга и исторических записей с помощью вывода Мамдани, обеспечивая динамическую адаптацию к изменениям в работе и устойчивость к неполным наборам данных. Треугольные и трапециевидные функции принадлежности в сочетании с правилами, основанными на экспертных знаниях (например, соотнесение высокой загруженности и низкого времени простоя с высокой эффективностью), эффективно управляют неточными переменными и лингвистической неоднозначностью.

Объединяя различные KPI, такие как рабочая скорость, время работы и показатели безопасности, система обеспечивает целостную оценку производительности горных машин, выходя за рамки традиционного одномерного анализа.

Модульная конструкция системы позволяет калибровать ее на основе исторических данных и оптимизировать с помощью машинного обучения, обеспечивая адаптацию к изменяющимся условиям эксплуатации и эволюции парка горных машин и их сенсорного оснащения.

В предложенной методике заложен большой потенциал для улучшения принятия решений в горнодобывающем секторе за счет предоставления практической информации для оптимизации распределения ресурсов, снижения затрат и повышения безопасности.

При сравнении с реальными данными можно убедиться, что предлагаемая нечеткая модель превосходит современные методы «черного ящика» не толь-

ко по точности, но и по устойчивости, интерпретируемости результатов, прозрачности и обоснованности оценки «эффективности».

СПИСОК ЛИТЕРАТУРЫ

1. *Semenova T., Martínez Santoyo J. Y.* Determining priority areas for the technological development of oil companies in Mexico // *Resources*. 2025, vol. 14, no. 1. DOI: 10.3390/resources14010018.

2. *Botyan E. Yu., Pushkarev A.* Improving the methodology of choosing machinery models for the formation of an excavator and vehicle fleet during the modernization of a mining transport system, with account for the Arctic specifics // *Transportation Research Procedia*. 2021, vol. 57, pp. 106–112. DOI: 10.1016/j.trpro.2021.09.031.

3. *Сафиуллин Р. Н., Кацуба Ю. Н., Унгефук А. А., Хисамутдинова Э. Л., Хохлов А. В.* Бутстрэп-метод мониторинга безопасности систем управления движением высокоавтоматизированных горных машин // *Горная промышленность*. — 2025. — № 15. — С. 73–80. DOI: 10.30686/1609-9192-2025-15-73-80.

4. *Fan C., Arachchilage C. B., Zhang N., Jiang B., Liu W. V.* Machine learning with Shapley additive explanations for evaluating mine truck productivity under real-site weather conditions at varying temporal resolutions // *International Journal of Mining, Reclamation and Environment*. 2024, vol. 38, no. 10, pp. 810–832. DOI: 10.1080/17480930.2024.2348877.

5. *Fan C., Arachchilage C. B., Zhang N., Jiang B., Liu W. V.* Prediction of truck productivity at mine sites using tree-based ensemble models combined with Gaussian mixture modelling // *International Journal of Mining, Reclamation and Environment*. 2023, vol. 37, no. 1, pp. 66–86. DOI: 10.1080/17480930.2022.2142425.

6. *Mohtasham M., Mirzaei-Nasirabad H., Askari-Nasab H., Alizadeh B.* Multi-stage optimization framework for the real-time truck decision problem in open-pit mines: a case study on Sungun copper mine // *International Journal of Mining, Reclamation and Environment*. 2022, vol. 36, no. 7, pp. 461–491. DOI: 10.1080/17480930.2022.2067709.

7. *Земенкова М. Ю., Чижевская Е. Л., Земенков Ю. Д.* Интеллектуальный мониторинг состояний объектов трубопроводного транспорта углеводородов с применением нейросетевых технологий // *Записки Горного института*. — 2022. — Т. 258. — С. 933–944. DOI: 10.31897/PMI.2022.105.

8. *Устюгов Д. Л., Ноа Сегура Э. Л., Ряховский М. С.* Использование влияния инфильтрации атмосферных осадков на пополнение запасов подземных вод гидрогеологического района Лаяна, Куба // *Горный журнал*. — 2024. — № 9. — С. 97–102. DOI: 10.17580/gzh.2024.09.15.

9. *Иванов С. Л., Сафрончук К. А., Олт Ю.* Обоснование и выбор конструктивных параметров зубчато-эксцентрикового механизма поршневого смазочно-заправочного агрегата для технического обслуживания горных машин // *Записки Горного института*. — 2021. — Т. 248. — С. 290–299. DOI: 10.31897/PMI.2021.2.13.

10. *Хамидов О. У., Шибанов Д. А., Шишкин П. В., Колпаков В. О.* Эффективность применения экскаваторов на карьерах Узбекистана // *Горная промышленность*. — 2024. — № 5. — С. 135–142. DOI: 10.30686/1609-9192-2024-5-135-142.

11. *Shojaee Barjoe S., Rodionov V., Vaziri Sereshk A. M.* Noise climate assessment in ceramic industries (Iran) using acoustic indices and its control solutions // *Advances in Environmental Technology*. 2025, vol. 11, no. 1, pp. 91–115. DOI: 10.22104/aet.2024.6922.1899.

12. *Bazhin V. Yu., Fernandez P. Al., Slobodin V. A.* Application of motor scrap in the production of aluminum-alloy ingots with thixotropic structure (under the conditions of the Republic of Cuba) // *Metallurgist*. 2025. DOI: 10.1007/s11015-025-02011-5.

13. *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. — С. 137–146. DOI: 10.30686/1609-9192-2025-1-137-14.

14. *Yujra Rivas E., Vyacheslavov A. V., Gogolinskiy K., Sapozhnikova K., Taymanov R.* Deformation monitoring systems for hydroturbine head-cover fastening bolts in hydroelectric power plants // *Sensors*. 2025, vol. 25, no. 8. DOI: 10.3390/s25082548.

15. *Цхададзе Н. В., Кучковская Н. В., Бондаренко М. П., Фролова В. Б., Лазарев М. П.* Разработка интеллектуальной системы управления жизненным циклом горнодобывающего предприятия на основе технологий индустрии 4.0 и циркулярной экономики // *Горная промышленность*. — 2024. — № 55. — С. 12–20. DOI: 10.30686/1609-9192-2024-55-12-20.

16. *Barjoe S. S., Gendler S.* Sustainable illumination: Experimental and simulation analysis of illumination for workers wellbeing in the workplace // *Heliyon*. 2024, vol. 10, no. 24, article e40745. DOI: 10.1016/j.heliyon.2024.e40745.

17. *Abdulrashid I. Chiang W., Sheu J., Mammadov S.* An interpretable machine learning framework for enhancing road transportation safety // *Transportation Research Part E: Logistics and Transportation Review*. 2025, vol. 195, article 103969. DOI: 10.1016/j.tre.2025.103969.

18. *Коновалов В. Б., Саркисов С. В., Кашеев Р. Л., Казаков Н. П., Руденко А. А., Харьковский В. В., Чепкин А. М., Горшенин А. В.* Патент № 2787806 С1 Российская Федерация, МПК G07C 5/08. Устройство контроля параметров движения транспортного средства (черный ящик): № 2022117397: заявл. 27.06.2022: опубл. 12.01.2023.

19. *Aydin F., Gümüş B.* Comparative analysis of multi-criteria decision-making methods for the assessment of optimal SVC location // *Bulletin of the Polish Academy of Sciences, Technical Sciences*. 2022, pp. 140555 – 140555. DOI: 10.24425/bpasts.2022.140555.

20. *Wang Y., Yeo G.-T.* Intermodal route selection for cargo transportation from Korea to Central Asia by adopting Fuzzy Delphi and Fuzzy ELECTRE I methods // *Maritime Policy & Management*. Routledge. 2018, vol. 45, no. 1, pp. 3–18. DOI:10.1080/03088839.2017.1319581.

21. *Lu W., Choi S.-B., Yeo G.-T.* Resilient route selection of oversized cargo transport: the case of South Korea – Kazakhstan // *The International Journal of Logistics Management*. 2022, vol. 33, no. 2, pp. 410 – 430. DOI: 10.1108/IJLM-11-2020-0445.

22. *Wang Z., Zhang M., Chu R., Zhao L.* Modeling and planning multimodal transport paths for risk and energy efficiency using AND/OR graphs and discrete ant colony optimization // *IEEE Access*. 2020, vol. 8, pp. 132642 – 132654. DOI: 10.1109/ACCESS.2020.3010376.

23. *Meethom W., Koohathongsumrit N.* A decision support system for road freight transportation route selection with new fuzzy numbers // *Foresight*. 2020, vol. 22, no. 4, pp. 505 – 527. DOI: 10.1108/FS-10-2019-0090.

24. *Koohathongsumrit N., Chankham W., Meethom W.* Multimodal transport route selection: An integrated fuzzy hierarchy risk assessment and multiple criteria decision-making approach // *Transportation Research Interdisciplinary Perspectives*. 2024, vol. 28, article 101252. DOI: 10.1016/j.trip.2024.101252.

25. *Ilyas M., Zhihong J., Irfan U., Almujiabah H.* A fuzzy logic-based risk assessment framework for the crude oil transportation supply chain // *Ocean Engineering*. 2024, vol. 311, article 118997. DOI: 10.1016/j.trip.2024.101252.

26. *Pálková A., Mašek J.* Fuzzy logic as a decision-making tool for transport request selection // *Transportation Research Procedia*. 2024, vol. 77, pp. 116 – 122. DOI: 10.1016/j.trpro.2024.01.015.

27. *Thompson E. A., Alimo P. K., Abudu R., Lu P.* Towards sustainable freight transportation in Africa: Complementarity of the fuzzy delphi and best-worst methods // *Sustainable Futures*. 2024, vol. 8, article 100371. DOI: 10.1016/j.sftr.2024.100371.

28. *Baban M., Baban C. F., Moisi B.* A fuzzy logic-based approach for predictive maintenance of grinding wheels of automated grinding lines / 23rd International Conference on Methods & Models in Automation & Robotics (MMAR). 2018, pp. 483 – 486. DOI: 10.1109/MMAR.2018.8486144.

29. *Selvalakshmi B., Palaniappan V., Subha N., Balamani T.* Predictive maintenance in industrial systems using data mining with fuzzy logic systems // *ICTACT Journal on Soft Computing*. 2024, vol. 14. DOI: 10.21917/ijsc.2024.0472.

30. *Semenova T., Martínez Santoyo J. Y.* Increasing the sustainability of the strategic development of oil producing companies in Mexico // *Resources*. 2024, vol. 13, no. 8. DOI: 10.3390/resources13080108.

31. *Kruk M. N., Perdomo Millán A., Torres Batista Y.* Evaluation of the efficiency of implementation of the sustainable development program at nickel-cobalt ore mining enterprises // *Sustainability*. 2025, vol. 17, no. 21. DOI: 10.3390/su17219441.

32. Chadi P., Princewill N. O., Nwachukwu A. N., Stanley T. E., Obibuike U. J., Izuwa N. C. Selection of candidate well for stimulation: a comparison of conventional method and artificial intelligence techniques (fuzzy logic) // *Petroleum and Coal*. 2024, vol. 66, no. 2, article 591. https://www.vurup.sk/wp-content/uploads/2024/04/PC-X_Chiadikaobi_2023_162.pdf. **WAS**

REFERENCES

1. Semenova T., Martínez Santoyo J. Y. Determining priority areas for the technological development of oil companies in Mexico. *Resources*. 2025, vol. 14, no. 1. DOI: 10.3390/resources14010018.
2. Botyan E. Yu., Pushkarev A. Improving the methodology of choosing machinery models for the formation of an excavator and vehicle fleet during the modernization of a mining transport system, with account for the Arctic specifics. *Transportation Research Procedia*. 2021, vol. 57, pp. 106–112. DOI: 10.1016/j.trpro.2021.09.031.
3. Safiullin R. N., Katsuba Yu. N., Ungefuk A. A., Khisamutdinova E. L., Khokhlov A. V. Bootstrap method for monitoring the safety of traffic control systems of highly automated mining machines. *Russian Mining Industry Journal*. 2025, no. 1S, pp. 73–80. [In Russ]. DOI: 10.30686/1609-9192-2025-1S-73-80.
4. Fan C., Arachchilage C. B., Zhang N., Jiang B., Liu W. V. Machine learning with Shapley additive explanations for evaluating mine truck productivity under real-site weather conditions at varying temporal resolutions. *International Journal of Mining, Reclamation and Environment*. 2024, vol. 38, no. 10, pp. 810–832. DOI: 10.1080/17480930.2024.2348877.
5. Fan C., Arachchilage C. B., Zhang N., Jiang B., Liu W. V. Prediction of truck productivity at mine sites using tree-based ensemble models combined with Gaussian mixture modelling. *International Journal of Mining, Reclamation and Environment*. 2023, vol. 37, no. 1, pp. 66–86. DOI: 10.1080/17480930.2022.2142425.
6. Mohtasham M., Mirzaei-Nasirabad H., Askari-Nasab H., Alizadeh B. Multi-stage optimization framework for the real-time truck decision problem in open-pit mines: a case study on Sungun copper mine. *International Journal of Mining, Reclamation and Environment*. 2022, vol. 36, no. 7, pp. 461–491. DOI: 10.1080/17480930.2022.2067709.
7. Zemenkova M., Chizhevskaya E., Zemenkov Y. I Intelligent monitoring of the condition of hydrocarbon pipeline transport facilities using neural network technologies. *Journal of Mining Institute*. 2022, vol. 258, pp. 933–944. [In Russ]. DOI: 10.31897/PMI.2022.105.
8. Ustyugov D. L., Noa Segura E. L., Ryakhovsky M. S. Influence of rainfall in filtration on ground water recharge in hydrogeological region La Yana, Cuba. *Gornyi Zhurnal*. 2024, no. 9, pp. 97–102. [In Russ]. DOI: 10.17580/gzh.2024.09.15.
9. Ivanov S., Safronchuk K., Olt Y. Justification and selection of design parameters of the eccentric gear mechanism of the piston lubrication and filling unit for the mining machines maintenance. *Journal of Mining Institute*. 2021, vol. 248, pp. 290–299. [In Russ]. DOI: 10.31897/PMI.2021.2.13.
10. Khamidov O. U., Shibanov D. A., Shishkin P. V., Kolpakov V. O. Efficiency of excavator's application in open pit mines of Uzbekistan. *Russian Mining Industry Journal*. 2024, no. 5, pp. 135–142. [In Russ]. DOI: 10.30686/1609-9192-2024-5-135-142.
11. Shojaee Barjoe S., Rodionov V., Vaziri Sereshk A. M. Noise climate assessment in ceramic industries (Iran) using acoustic indices and its control solutions. *Advances in Environmental Technology*. 2025, vol. 11, no. 1, pp. 91–115. DOI: 10.22104/aet.2024.6922.1899.
12. Bazhin V. Yu., Fernandez P. AL., Slobodin V. A. Application of motor scrap in the production of aluminum-alloy ingots with thixotropic structure (under the conditions of the Republic of Cuba). *Metalurgist*. 2025. DOI: 10.1007/s11015-025-02011-5.
13. Kadyrova G. M., Krasnyukova 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 Journal*. 2025, no. 1, pp. 137–146. [In Russ]. DOI: 10.30686/1609-9192-2025-1-137-14.
14. Yujra Rivas E., Vyacheslavov A. V., Gogolinskiy K., Sapozhnikova K., Taymanov R. Deformation monitoring systems for hydroturbine head-cover fastening bolts in hydroelectric power plants. *Sensors*. 2025, vol. 25, no. 8. DOI: 10.3390/s25082548.

15. Tskhadadze N. V., Kuchkovskaya N. V., Bondarenko M. P., Frolova V. B., Lazarev M. P. Designing a smart life cycle management system for a mining enterprise based on Industry 4.0 and circular economy technologies. *Russian Mining Industry Journal*. 2024, no. 5S, pp. 12 – 20. [In Russ]. DOI: 10.30686/1609-9192-2024-5S-12-20.
16. Barjoe S. S., Gendler S. Sustainable illumination: Experimental and simulation analysis of illumination for workers wellbeing in the workplace. *Heliyon*. 2024, vol. 10, no. 24, article e40745. DOI: 10.1016/j.heliyon.2024.e40745.
17. Abdulrashid I., Chiang W., Sheu J., Mammadov S. An interpretable machine learning framework for enhancing road transportation safety. *Transportation Research Part E: Logistics and Transportation Review*. 2025, vol. 195, article 103969. DOI: 10.1016/j.tre.2025.103969.
18. Konovalov V. B., Sarkisov S. V., Kashcheev R. L., Kazakov N. P., Rudenko A. A., Har'kovskij V. V., Chepkin A. M., Gorshenin A. V. *Patent RU 2787806 C1, MPK G07C 5/08, 12.01.2023*. [In Russ].
19. Aydin F., Gümüş B. Comparative analysis of multi-criteria decision-making methods for the assessment of optimal SVC location. *Bulletin of the Polish Academy of Sciences, Technical Sciences*. 2022, pp. 140555 – 140555. DOI: 10.24425/bpasts.2022.140555.
20. Wang Y., Yeo G.-T. Intermodal route selection for cargo transportation from Korea to Central Asia by adopting Fuzzy Delphi and Fuzzy ELECTRE I methods. *Maritime Policy & Management. Routledge*. 2018, vol. 45, no. 1, pp. 3 – 18. DOI:10.1080/03088839.2017.1319581.
21. Lu W., Choi S.-B., Yeo G.-T. Resilient route selection of oversized cargo transport: the case of South Korea – Kazakhstan. *The International Journal of Logistics Management*. 2022, vol. 33, no. 2, pp. 410 – 430. DOI: 10.1108/IJLM-11-2020-0445.
22. Wang Z., Zhang M., Chu R., Zhao L. Modeling and planning multimodal transport paths for risk and energy efficiency using AND/OR graphs and discrete ant colony optimization. *IEEE Access*. 2020, vol. 8, pp. 132642 – 132654. DOI: 10.1109/ACCESS.2020.3010376.
23. Meethom W., Koohathongsumrit N. A decision support system for road freight transportation route selection with new fuzzy numbers. *Foresight*. 2020, vol. 22, no. 4, pp. 505 – 527. DOI: 10.1108/FS-10-2019-0090.
24. Koohathongsumrit N., Chankham W., Meethom W. Multimodal transport route selection: An integrated fuzzy hierarchy risk assessment and multiple criteria decision-making approach. *Transportation Research Interdisciplinary Perspectives*. 2024, vol. 28, article 101252. DOI: 10.1016/j.trip.2024.101252.
25. Ilyas M., Zhihong J., Irfan U., Almujiabah H. A fuzzy logic-based risk assessment framework for the crude oil transportation supply chain. *Ocean Engineering*. 2024, vol. 311, article 118997. DOI: 10.1016/j.trip.2024.101252.
26. Pálková A., Mašek J. Fuzzy logic as a decision-making tool for transport request selection. *Transportation Research Procedia*. 2024, vol. 77, pp. 116 – 122. DOI: 10.1016/j.trpro.2024.01.015.
27. Thompson E. A., Alimo P. K., Abudu R., Lu P. Towards sustainable freight transportation in Africa: Complementarity of the fuzzy delphi and best-worst methods. *Sustainable Futures*. 2024, vol. 8, article 100371. DOI: 10.1016/j.sftr.2024.100371.
28. Baban M., Baban C. F., Moisi B. A fuzzy logic-based approach for predictive maintenance of grinding wheels of automated grinding lines. *23rd International Conference on Methods & Models in Automation & Robotics (MMAR)*. 2018, pp. 483 – 486. DOI: 10.1109/MMAR.2018.8486144.
29. Selvalakshmi B., Palaniappan V., Subha N., Balamani T. Predictive maintenance in industrial systems using data mining with fuzzy logic systems. *ICTACT Journal on Soft Computing*. 2024, vol. 14. DOI: 10.21917/ijsc.2024.0472.
30. Semenova T., Martínez Santoyo J. Y. Increasing the sustainability of the strategic development of oil producing companies in Mexico. *Resources*. 2024, vol. 13, no. 8. DOI: 10.3390/resources13080108.
31. Kruk M. N., Perdomo Millán A., Torres Batista Y. Evaluation of the efficiency of implementation of the sustainable development program at nickel-cobalt ore mining enterprises. *Sustainability*. 2025, vol. 17, no. 21. DOI: 10.3390/su17219441.
32. Chadi P., Princewill N. O., Nwachukwu A. N., Stanley T. E., Obibuike U. J., Izuwa N. C. Selection of candidate well for stimulation: a comparison of conventional method and artificial intelligence techniques (fuzzy logic). *Petroleum and Coal*. 2024, vol. 66, no. 2, article 591. https://www.vurup.sk/wp-content/uploads/2024/04/PC-X_Chiadikaobi_2023_162.pdf.

ИНФОРМАЦИЯ ОБ АВТОРАХ

*Сафиуллин Равилл Нуруллович*¹ — д-р техн. наук,
профессор, e-mail: safravi@mail.ru,

ORCID ID: 0000-0002-8765-6461,

*Парра Ариас Сунильда*¹ — аспирант,

e-mail: zuny1503@gmail.com,

ORCID ID: 0000-0003-1715-7998,

*Сафиуллин Руслан Равиллович*¹ — канд. техн. наук,

доцент, e-mail: safiyllin@yandex.ru,

ORCID ID: 0000-0003-2315-3678,

Присяжнюк Михаил Сергеевич — канд. техн. наук,

председатель Комитета Ленинградской области по транспорту,

e-mail: transportlo@lenreg.ru,

Симонова Лариса Анатольевна — д-р техн. наук,

член-корреспондент Российской академии естественных наук,

профессор, Набережночелнинский (институт) филиал

Казанского федерального университета,

e-mail: lasimonova@mail.ru, ORCID ID: 0000-0002-3653-1845,

¹ Санкт-Петербургский горный университет императрицы Екатерины II.

Для контактов: Парра А.С., e-mail: zuny1503@gmail.com.

INFORMATION ABOUT THE AUTHORS

*P.N. Safiullin*¹, Dr. Sci. (Eng.), Professor,

e-mail: safravi@mail.ru,

ORCID ID: 0000-0002-8765-6461,

*Zunilda Arias Parra*¹, Graduate Student,

e-mail: zuny1503@gmail.com,

ORCID ID: 0000-0003-1715-7998,

*R.R. Safiullin*¹, Cand. Sci. (Eng.),

Assistant Professor, e-mail: safiyllin@yandex.ru,

ORCID ID: 0000-0003-2315-3678,

M.S. Prisyazhnyuk, Chairman of the Leningrad Region Transport Committee,

Saint-Petersburg, Russia, e-mail: transportlo@lenreg.ru,

L.A. Simonova, Dr. Sci. (Eng.), Professor, Corresponding Member

of the Russian Academy of Natural Sciences,

Naberezhnye Chelny (Institute) Branch of Kazan Federal University,

Naberezhnye Chelny, Russia, e-mail: lasimonova@mail.ru,

ORCID ID: 0000-0002-3653-1845,

¹ Empress Catherine II Saint-Petersburg Mining University,

199106, Saint-Petersburg, Russia.

Corresponding author: Z.A. Parra, e-mail: zuny1503@gmail.com.

Получена редакцией 01.09.2025; получена после рецензии 12.11.2025; принята к печати 10.02.2026.

Received by the editors 01.09.2025; received after the review 12.11.2025; accepted for printing 10.02.2026.

