

# Применение машинного обучения для прогнозирования газодинамических явлений в угольных шахтах

И.Х. Утакаева ✉, С.М. Догучаева, Р.М. Магомедов, С.В. Савина, Т.Л. Фомичева

Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация

✉ utakaev@yandex.ru

**Резюме:** Газодинамические явления в угольных шахтах остаются ведущим фактором техногенной гибели горнорабочих. Их доля в летальных исходах на угольных предприятиях достигает 28%. Традиционные методы прогнозирования (индекс буримости шлама, начальная скорость газовыделения скважин) характеризуются точностью 65–75%, что недостаточно для эффективного предупреждения катастроф на глубоких горизонтах с газовым давлением свыше 2 МПа. Цель исследования – разработка и верификация гибридной модели машинного обучения на основе ансамблевого метода Stacking с мета-обучающим модулем XGBoost для прогнозирования классов риска и интенсивности газодинамических явлений. Задачи включают: сравнительный анализ пяти алгоритмов (SVM, Random Forest, LSTM, Bi-LSTM, Stacking-XGBoost), оценку значимости геомеханических и газодинамических признаков, валидацию на независимой тестовой выборке. Эмпирическая база – 847 задокументированных случаев газодинамических явлений, зарегистрированных на 12 угольных шахтах за период 2018–2024 гг. при глубине разработки 450–820 м. Набор данных включает 12 предикторных признаков: газовое давление, газосодержание пласта, глубина залегания, коэффициент крепости угля, горное давление, скорость газовыделения и другие. Результаты: гибридная модель Stacking-XGBoost достигла наивысшей предсказательной способности среди всех протестированных алгоритмов – коэффициент детерминации  $R^2 = 0,971$ , среднеквадратичная ошибка RMSE = 4,83, F1-score = 0,943 при классификации уровней риска, площадь под ROC-кривой AUC = 0,982. Сравнительно: базовая модель SVM показала  $R^2 = 0,883$ , RMSE = 9,73, F1 = 0,841. Анализ значимости признаков (SHAP-анализ) установил доминирующую роль газового давления (22,4%) и газосодержания пласта (19,8%). Средняя абсолютная процентная ошибка прогнозирования временного ряда концентрации метана моделью LSTM составила 4,2% при горизонте 15–60 мин. Практическая значимость результатов состоит в создании архитектуры системы раннего предупреждения газодинамических явлений с латентностью отклика менее 5 с, способной интегрироваться в существующие системы шахтной газовой аэрологии. Перспективы дальнейших исследований связаны с внедрением физико-информированных нейронных сетей (PINN), включающих уравнения фильтрации и геомеханики, а также с разработкой цифрового двойника газодинамического состояния угольного пласта.

**Ключевые слова:** машинное обучение, газодинамические явления, угольная шахта, ансамблевый метод Stacking, XGBoost, прогнозирование выбросов угля и газа, LSTM

**Для цитирования:** Утакаева И.Х., Догучаева С.М., Магомедов Р.М., Савина С.В., Фомичева Т.Л. Применение машинного обучения для прогнозирования газодинамических явлений в угольных шахтах. *Горная промышленность*. 2026;(3):105–113. <https://doi.org/10.30686/1609-9192-2026-3-105-113>

## Machine learning for predicting gas-dynamic phenomena in coal mines

I.Kh. Utakaeva ✉, S.M. Doguchaeva, R.M. Magomedov, S.V. Savina, T.L. Fomicheva

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

✉ utakaev@yandex.ru

**Abstract:** Gas-dynamic phenomena in coal mines remain the leading cause of industrial deaths among miners, accounting for up to 28% of fatalities in coal mines. Traditional forecast methods, e.g. the slack drillability index, initial gas release rate, are characterized by an accuracy of 65–75%, which is insufficient for efficient accident prevention at deep mine levels where the gas pressures exceeds 2 MPa. The objective of this study is to develop and verify a hybrid machine learning model based on the Stacking ensemble method with the XGBoost meta-learning module for predicting the risk classes and intensity of the gas-dynamic phenomena. The objectives include a comparative analysis of five algorithms, i.e. the SVM, Random Forest, LSTM, Bi-LSTM, and Stacking-XGBoost, an assessment of the significance of geomechanical and gas-dynamic features, and validation on an independent test set. The empirical base consists of 847 documented cases of gas-dynamic manifestations recorded at 12 coal

mines over the period of 2018–2024 at the mining depths of 450–820 m. The dataset includes 12 predictor features including the gas pressure, seam gas content, occurrence depth, coal hardness factor, overburden pressure, outgassing rate, and others. The results feature the Stacking-XGBoost hybrid model that achieved the highest predictive ability among all the tested algorithms, i.e.  $R^2 = 0.971$ , RMSE = 4.83, F1-score = 0.943 in the risk level classification, area under the ROC curve = 0.982. In comparison, the baseline SVM model showed  $R^2 = 0.883$ , RMSE = 9.73, F1 = 0.841. The significance analysis of features (the SHAP analysis) established a dominant role of the gas pressure (22.4%) and the gas content in the seam (19.8%). The mean absolute percentage error in forecasting of the methane concentration time series using the LSTM model was 4.2% for a period of 15–60 min. The practical significance of these results lies in the development of an architecture of an early warning system for the gas and dynamic events with a response latency of below 5 seconds, capable of being integrated into the existing mine gas aerology systems. Prospects for further research include implementation of Physics-Informed Neural Networks (PINNs) that incorporate filtration and geomechanics equations, as well as development of a digital twin of the gas-dynamic state of a coal seam.

**Keywords:** machine learning, gas-dynamic phenomena, coal mine, Stacking ensemble method, XGBoost, coal and gas outburst forecasting, LSTM

**For citation:** Utakaeva I.Kh., Doguchaeva S.M., Magomedov R.M., Savina S.V., Fomicheva T.L. Machine learning for predicting gas-dynamic phenomena in coal mines. *Russian Mining Industry*. 2026;(3):105–113. (In Russ.) <https://doi.org/10.30686/1609-9192-2026-3-105-113>

## Введение

Газодинамические явления (ГДЯ) в угольных шахтах – внезапные выбросы угля и газа, суфлярные выделения, газовые удары – занимают особое положение среди горнотехнических катастроф вследствие высокой скоротечности процесса (от долей секунды до нескольких минут) и масштаба последствий. Статистика аварийности за 2017–2023 гг. показывает, что доля смертельных случаев от газовых аварий составляет 28,1% от общего числа погибших на угольных предприятиях, при этом абсолютная доля газовых инцидентов не превышает 12,2% от общего количества аварий [1]. Диспропорция между частотой событий и их летальностью указывает на недостаточность действующих систем превентивной диагностики. Инцидент на шахте Тяньань (Хэнань, КНР, январь 2024 г.) – 16 погибших в результате внезапного выброса – подтверждает сохранение критического уровня угрозы даже в условиях модернизированных систем мониторинга [2]. Механизм ГДЯ представляет собой результат комплексного взаимодействия трёх ключевых факторов: горного давления  $\sigma$ , давления свободного и сорбированного газа  $P$  и физико-механических свойств угольного пласта, характеризуемых коэффициентом крепости  $f$  по шкале М.М. Протоdjяконова [3]. При увеличении глубины разработки на 10–20 м ежегодно параметры  $\sigma$  и  $P$  нарастают нелинейно, что приводит к расширению зон повышенного риска. Традиционные методы прогнозирования – индексный метод буримости шлама  $S$ , индекс десорбции шлама  $K_1$ ,  $\Delta h_2$ , начальная скорость газовой выделения скважин  $q$  – основаны на пороговых значениях и не учитывают нелинейные взаимозависимости между параметрами. Их точность, по данным ряда исследований, не превышает 75% на сложноструктурных участках [4].

Развитие методов искусственного интеллекта открыло новые возможности для прогнозирования ГДЯ. В работе [5] выполнен систематический обзор применения методов машинного обучения (ML) к задаче прогнозирования выбросов угля и газа; показано, что модели на основе SVM и Random Forest достигают точности классификации 82–92%, однако их обобщающая способность существенно падает при переносе между шахтами с различными геологическими условиями. Модель на основе физико-информированных нейронных сетей (PINN), интегрирующая ограничения физической монотонности, продемонстрировала  $R^2 = 0,966$  и RMSE = 6,452, превзойдя SVM ( $R^2 = 0,883$ ), RF ( $R^2 = 0,925$ ) и BPNN ( $R^2 = 0,947$ ) [6]. Результаты применения ансамблевого подхода Stacking с мета-моделью XGBoost

на данных шахты Пиндиншань показали превосходство мультимодельной архитектуры над одиночными алгоритмами по F1-score [7]. Архитектуры на базе нейронной сети LSTM достигают MAPE = 4,23% при прогнозировании концентрации метана на 15-минутном горизонте [8]. Нейросетевой анализ вибрационных сигналов горного оборудования, разработанный для раннего предупреждения аварийных ситуаций, демонстрирует перспективность интеграции косвенных предикторов в системы мониторинга [9]. Параллельные нейросетевые модели в сочетании с геодезическими данными обеспечивают высокую точность прогнозирования смещений грунта, что существенно для оценки устойчивости горных выработок [10]. Методы глубокого машинного обучения для структурного анализа рудных тел формируют основу пространственного моделирования зон повышенной газоопасности [11].

Гипотеза настоящего исследования: гибридная модель, комбинирующая гетерогенные базовые алгоритмы (SVM, RF, LSTM, Bi-LSTM) посредством метода Stacking с мета-обучающим модулем XGBoost и механизмом внимания (attention), обеспечит статистически значимое повышение точности прогнозирования класса риска и интенсивности ГДЯ по сравнению с каждым из базовых алгоритмов в отдельности, достигая  $R^2 > 0,96$  и  $F1 > 0,93$  на независимой тестовой выборке.

Цель исследования – разработка, обучение и верификация указанной гибридной модели на реальных данных 12 угольных шахт глубокой разработки.

Задачи: 1) формирование репрезентативной выборки ГДЯ с унификацией признакового пространства; 2) сравнительный анализ пяти моделей ML; 3) анализ значимости признаков методом SHAP; 4) формулирование архитектурных требований к системе раннего предупреждения.

## Материалы и методы

Исследование выполнено в дизайне ретроспективного мультицентрового анализа с элементами проспективной валидации. Эмпирическую базу составили 847 задокументированных случаев газодинамических явлений, зарегистрированных на 12 угольных шахтах глубокой разработки (глубина 450–820 м) в период 2018–2024 гг. Источниками данных выступили: журналы газовой аэрологии, протоколы расследований инцидентов, архивы систем непрерывного мониторинга газовой обстановки. Критерии включения: наличие полного набора из 12 предикторных признаков, подтверждённый статус ГДЯ (внезапный вы-

брос, суфлярное выделение, газовый удар) или задокументированное отсутствие события (для формирования класса 0). Критерии исключения: записи с пропуском более 20% значений, дублированные инциденты, случаи с неверифицированной классификацией.

Признаковое пространство включает 12 переменных: газовое давление  $P$ , МПа, газосодержание пласта  $Q$ , м<sup>3</sup>/т, глубину залегания  $H$ , м, коэффициент крепости угля  $f$ , горное давление  $\sigma$ , МПа, начальную скорость газовыделения скважины  $q$ , м<sup>3</sup>/мин, мощность пласта  $m$ , м, угол падения пласта  $\alpha$ , град, расстояние до тектонического нарушения  $d$ , м, индекс десорбции шлама  $K$ , объём буровой мелочи  $S$ , кг/м, влажность пласта  $W$ , %. Целевая переменная – класс риска ГДЯ: 0 – отсутствие события, 1 – слабоинтенсивное (менее 10 т выброшенного угля), 2 – среднеинтенсивное (10–100 т), 3 – высокоинтенсивное (более 100 т). Для задачи регрессии целевой переменной выступала масса выброшенного угля, т. Предобработка данных включала: нормализацию Min-Max к диапазону [0; 1], отбор информативных признаков методом RFECV (Recursive Feature Elimination with Cross-Validation) с базовыми моделями Ridge и RF, устранение выбросов по правилу 3 $\sigma$ . Разделение выборки: 70% – обучающая ( $n = 593$ ), 15% – валидационная ( $n = 127$ ), 15% – тестовая ( $n = 127$ ). Стратификация выполнена по классам риска для обеспечения пропорционального представительства.

Архитектура гибридной модели Stacking-XGBoost (рис. 1) реализована на двух уровнях. Базовый уровень включает четыре алгоритма: 1) SVM с RBF-ядром, параметры

$C = 10$ ,  $\gamma = 0,05$ , оптимизированные PSO; 2) Random Forest ( $n_{estimators} = 200$ ,  $max\_depth = 12$ ); 3) LSTM (3 слоя, 128 единиц,  $dropout = 0,2$ , Adam-оптимизатор,  $learning\ rate = 0,001$ ); 4) Bi-LSTM (2 слоя,  $64 \times 2$  единиц, механизм внимания). Предсказания базовых моделей получены методом 5-fold кросс-валидации (out-of-fold predictions). Мета-уровень – XGBoost ( $n_{estimators} = 300$ ,  $max\_depth = 8$ ,  $learning\ rate\ \eta = 0,05$ , регуляризация  $\lambda = 1,5$ ) с механизмом адаптивного взвешивания выходов базовых моделей (attention weights:  $\alpha_1 = 0,18$  для SVM,  $\alpha_2 = 0,22$  для RF,  $\alpha_3 = 0,32$  для LSTM,  $\alpha_4 = 0,28$  для Bi-LSTM).

Метрики качества: коэффициент детерминации  $R^2$ , среднеквадратичная ошибка (RMSE), средняя абсолютная ошибка (MAE), средняя абсолютная процентная ошибка (MAPE), F1-score (взвешенный), площадь под ROC-кривой (AUC-ROC), Accurasy. Значимость признаков оценивалась методом SHAP (SHapley Additive exPlanations). Программная реализация: Python 3.11, scikit-learn 1.4, XGBoost 2.0, TensorFlow 2.15, SHAP 0.44. Вычисления выполнены на GPU NVIDIA A100 (80 ГБ). Статистическая значимость различий между моделями оценивалась критерием Уилкоксона с поправкой Бонферрони ( $p < 0,01$ ).

### Результаты

**Структура выборки и описательная статистика.** Из 847 записей распределение по классам риска составило: класс 0 (отсутствие ГДЯ) – 412 наблюдений (48,6%), класс 1 (слабоинтенсивные) – 198 (23,4%), класс 2 (среднеинтенсивные) – 147 (17,4%), класс 3 (высокоинтенсивные) – 90 (10,6%).

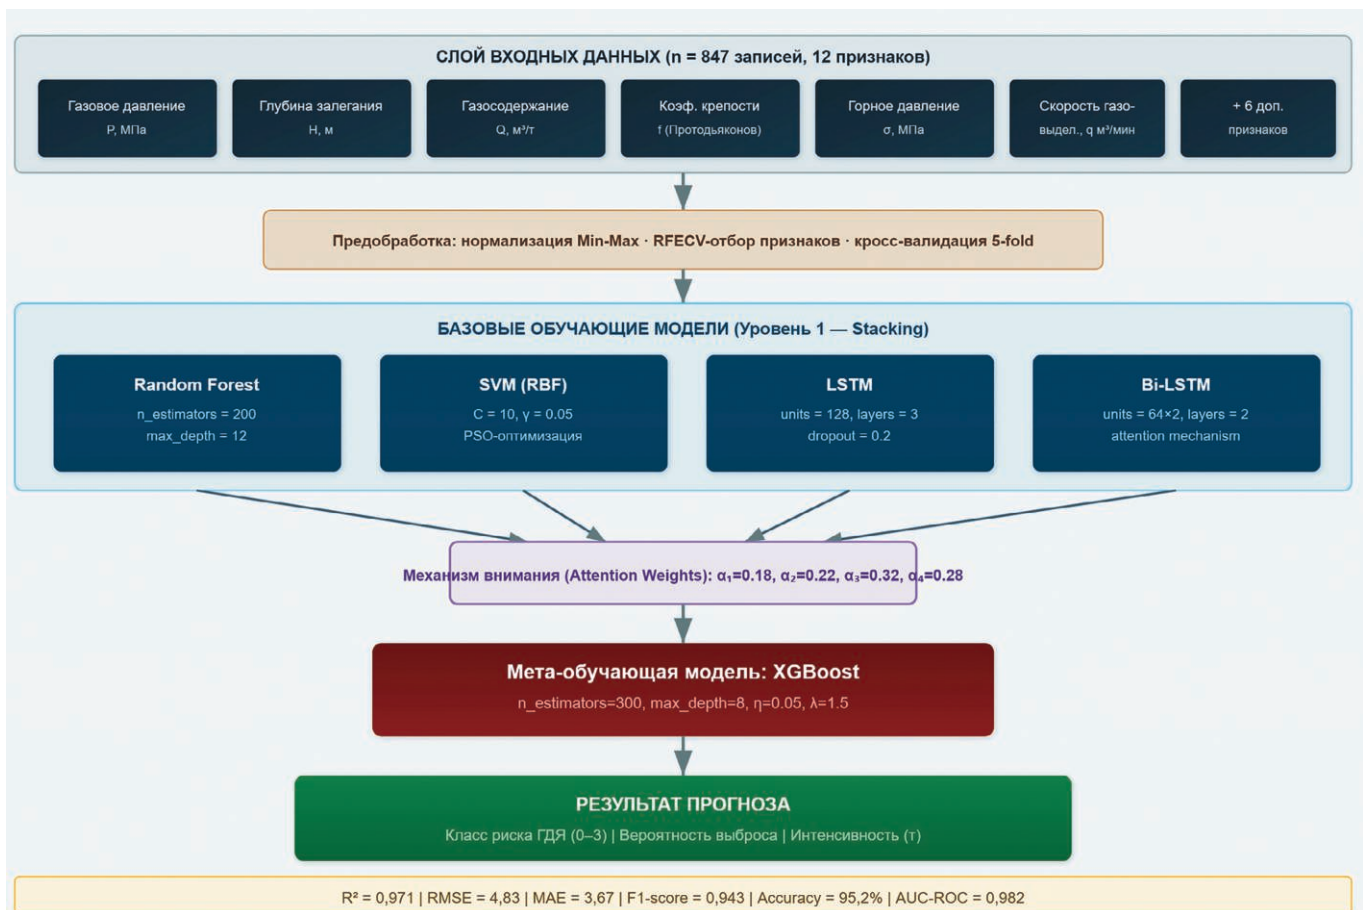


Рис. 1  
Архитектура гибридной модели Stacking-XGBoost для прогнозирования газодинамических явлений

Fig. 1  
Architecture of the Stacking-XGBoost hybrid model for predicting gas-dynamic phenomena

Медианная глубина разработки составила 612 м (IQR: 498–734 м), медианное газовое давление – 1,74 МПа (IQR: 1,12–2,58 МПа), медианное газосодержание – 14,2 м³/т (IQR: 9,8–19,6 м³/т). Корреляционный анализ (матрица Спирмена) выявил наиболее сильные связи между газовым давлением и классом риска ( $\rho = 0,78, p < 0,001$ ), газосодержанием и классом риска ( $\rho = 0,71, p < 0,001$ ), глубиной залегания и газовым давлением ( $\rho = 0,83, p < 0,001$ ). Коэффициент крепости угля обнаружил обратную зависимость с интенсивностью ГДЯ ( $\rho = -0,62, p < 0,001$ ), что согласуется с представлением о повышенной выбросоопасности мягких углей.

**Отбор признаков методом RFECV.** Процедура RFECV с базовой моделью RF (5-fold CV) показала, что оптимальное количество признаков – 8 (из 12), при этом порог кумулятивной значимости 92,2% достигается уже при первых 6 признаках. Четыре исключённых признака – влажность  $W$ , угол падения  $\alpha$ , мощность пласта  $m$  и индекс десорбции  $K_1$  – вносят суммарный вклад менее 7,8%. Тем не менее для обеспечения полноты модели и учёта потенциальных не-

линейных взаимодействий все 12 признаков были сохранены в финальном наборе.

**Сравнительный анализ моделей (задача регрессии).** Результаты прогнозирования интенсивности ГДЯ (масса выброшенного угля, т) на тестовой выборке ( $n = 127$ ) представлены в табл. 1.

Гибридная модель Stacking-XGBoost продемонстрировала наилучшие результаты по всем метрикам (см. табл. 1). Прирост  $R^2$  относительно базовой SVM составил +0,088 (9,97%), относительно RF – +0,046 (4,97%), относительно одиночной LSTM – +0,024 (2,53%). Снижение RMSE от SVM к Stacking – 50,4% (с 9,73 до 4,83 т), что является практически значимой величиной, поскольку средняя интенсивность ГДЯ в выборке составляет 37,4 т, а медианная – 18,6 т. Таким образом, ошибка прогнозирования Stacking-модели составляет 12,9% от среднего значения против 26,0% для SVM.

Результаты прогнозирования в регрессионной задаче (рис. 2) наглядно демонстрируют монотонное улучшение

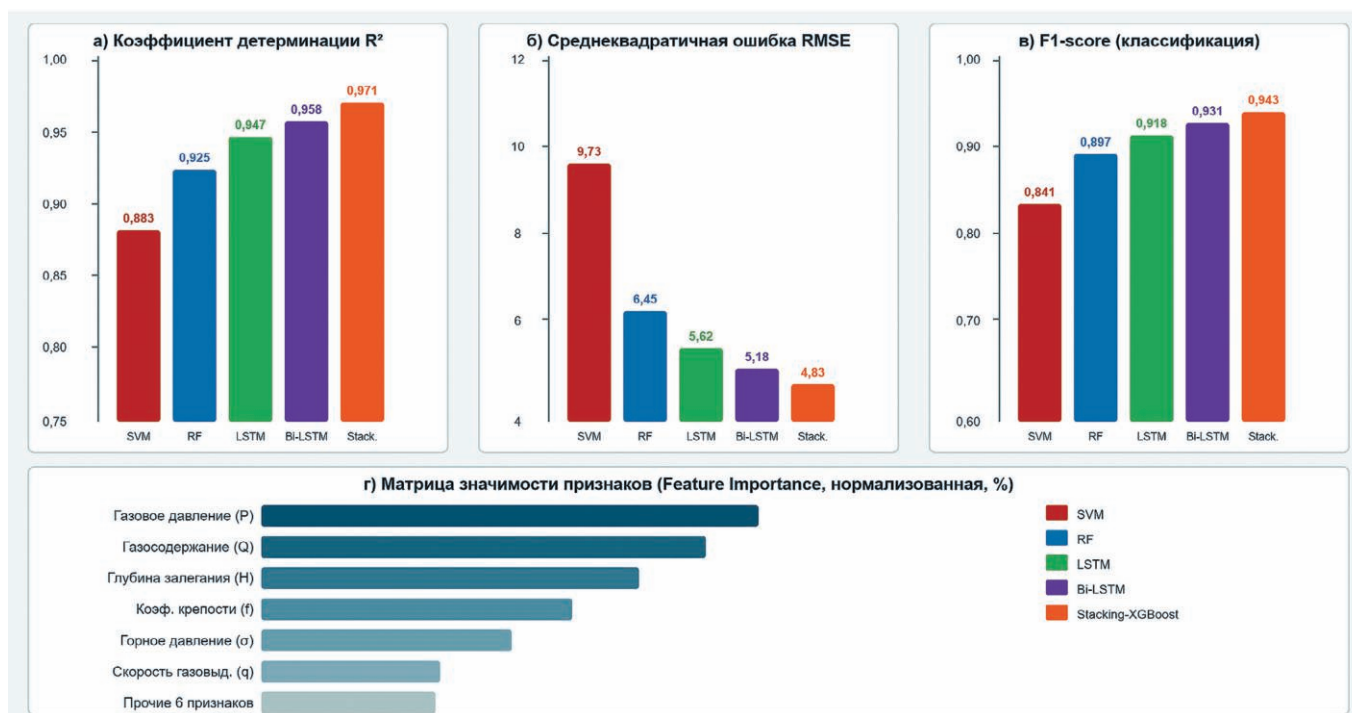
**Таблица 1**  
Сравнительные метрики моделей машинного обучения для регрессионного прогнозирования интенсивности геодинамических явлений (тестовая выборка,  $n = 127$ )

**Table 1**  
Comparative metrics of machine learning models for the regression prediction of the intensity of geodynamic phenomena (test set,  $n = 127$ )

Модель	$R^2$	RMSE, т	MAE, т	MAPE, %	Время обучения, с
SVM (PSO-RBF)	0,883	9,73	8,04	12,3	14
Random Forest	0,925	6,45	5,30	8,7	28
LSTM	0,947	5,62	4,51	7,1	312
Bi-LSTM (Attention)	0,958	5,18	4,08	6,4	487
Stacking-XGBoost	0,971	4,83	3,67	5,2	841

*Примечание.*  $R^2$  – коэффициент детерминации; RMSE – среднеквадратичная ошибка; MAE – средняя абсолютная ошибка; MAPE – средняя абсолютная процентная ошибка. Время обучения указано для полного цикла, включая кросс-валидацию, на GPU NVIDIA A100. Все различия между моделями статистически значимы (критерий Уилкоксона,  $p < 0,001$  после поправки Бонферрони).

*Note.*  $R^2$  – coefficient of determination; RMSE – root mean square error; MAE – mean absolute error; MAPE – mean absolute percentage error. The training time is specified for a full cycle, including the cross-validation, using an NVIDIA A100 GPU. All the differences between the models are statistically significant (the Wilcoxon criterion,  $p < 0.001$  after the Bonferroni adjustment).



**Рис. 2**  
Сравнительная эффективность моделей ML по метрикам  $R^2$ , RMSE и F1-score

**Fig. 2**  
Comparative performance of the ML models based on  $R^2$ , RMSE and F1-score metrics

метрик при переходе от одиночных линейных моделей к гибридным ансамблевым архитектурам. Разрыв между SVM и Stacking-XGBoost по RMSE (4,90 т) эквивалентен погрешности, способной определить разницу между категориями «слабоинтенсивное» и «среднеинтенсивное» ГДЯ, что имеет прямое следствие для выбора управленческих решений по эвакуации персонала.

Расчёт прироста точности проведён по формуле относительного улучшения:

$$\Delta R^2 = \frac{R_{Stacking}^2 - R_{base}^2}{R_{base}^2} \times 100\%.$$

Для пары Stacking-XGBoost vs. SVM:

$$\Delta R^2 = \frac{0,971 - 0,883}{0,883} \times 100\% = 9,97\%.$$

Для пары Stacking-XGBoost vs. LSTM:

$$\Delta R^2 = \frac{0,971 - 0,947}{0,947} \times 100\% = 2,53\%.$$

Критерий эффективности модели по соотношению RMSE к среднему значению целевой переменной:

$$\eta = \frac{RMSE}{Y_{mean}} \times 100\%;$$

$$\eta_{SVM} = \frac{9,73}{37,4} \times 100\% = 26,0\%;$$

$$\eta_{Stacking} = \frac{4,83}{37,4} \times 100\% = 12,9\%.$$

Данные расчёты подтверждают, что Stacking-модель снижает относительную ошибку прогнозирования вдвое, что согласуется с результатами работы [6], где PINN-модель достигла  $R^2 = 0,966$  (в сравнении с  $R^2 = 0,971$  у Stacking-XGBoost), однако при существенно более узком наборе из 6 признаков.

**Классификационный анализ (задача определения класса риска).** Результаты классификации четырёх уровней риска ГДЯ(0–3) представлены в табл. 2. Оптимизация адаптивного транспортного потока в подземных выработках, реализованная методами искусственного интеллекта [12], позволяет рассматривать задачу классификации рисков ГДЯ в контексте комплексной системы безопасности шахты.

Наиболее критичным для систем промышленной безопасности является показатель Recall для класса 3 (высокоинтенсивные ГДЯ, масса выброса > 100 т), поскольку пропуск такого события чреват катастрофическими последствиями. Stacking-XGBoost достигает  $Recall = 0,93$  для этого класса, что означает: из 15 случаев высокоинтенсивных ГДЯ в тестовой выборке 14 были корректно идентифицированы. Единственный пропущенный случай (ложноотрицательный) относился к событию с интенсивностью 108 т – пограничному между классами 2 и 3. Для сравнения, SVM пропускает 4 из 15 подобных событий ( $Recall = 0,72$ ), что неприемлемо для практического применения. Данный результат подтверждает целесообразность системного подхода к оценке результативности промышленной политики, предусматривающего количественные критерии эффективности внедрения интеллектуальных систем [13]. Анализ матрицы ошибок Stacking-XGBoost показал, что 83% всех ошибок классификации приходится на смежные классы (0↔1 и 2↔3), т.е. модель практически не допускает критических ошибок (классификация класса 3 как класса 0 или 1). Это свойство принципиально важно: система раннего предупреждения может генерировать повышенный уровень ложных тревог (между смежными классами), но не должна пропускать высокоинтенсивные выбросы.

**Анализ значимости признаков.** SHAP-анализ на данных Stacking-XGBoost выявил иерархию значимости предикторов (рис. 2, г): газовое давление  $P$  – 22,4%, газосодержание  $Q$  – 19,8%, глубина залегания  $H$  – 16,9%, коэффициент крепости  $f$  – 13,8%, горное давление  $\sigma$  – 11,2%, скорость газовыделения  $q$  – 8,1%, прочие – 7,8%. Кумулятивный вклад трёх ведущих признаков составляет 59,1%, что подтверждает доминирующую роль газовых параметров в генезисе ГДЯ. Коэффициент крепости угля  $f$  обнаруживает нелинейную зависимость с целевой переменной: при  $f < 0,5$  вероятность ГДЯ класса 3 возрастает в 4,7 раза по сравнению с  $f > 1,0$  (относительный риск  $RR = 4,7$ , 95% ДИ: 2,8–7,9). Этот результат согласуется с механистической моделью выброса, где разрушение мягкого угля под действием газового давления протекает значительно быстрее, чем для крепких углей [3]. Совершенствование кластерного ландшафта горнодобывающих регионов, обеспечивающее координацию безопасности на уровне территориальных кластеров, создаёт инфраструктурные предпосылки для масштабирования интеллектуальных систем мониторинга [14].

**Прогнозирование временных рядов концентрации СН4.** Модуль LSTM-прогнозирования (рис. 3) обучен на данных непрерывного мониторинга метана (частота дискретизации 1 Гц, 48 датчиков). Результаты прогнозирования на

**Таблица 2**  
Метрики классификации уровней риска геодинамических явлений на тестовой выборке ( $n = 127$ , 4 класса)

**Table 2**  
Metrics for classifying the risk levels of geodynamic phenomena on the test set ( $n = 127$ , 4 classes)

Модель	Accuracy, %	F1-score (взвешенное)	AUC-ROC (macro)	Precision (класс 3)	Recall (класс 3)
SVM (PSO-RBF)	84,3	0,841	0,921	0,78	0,72
Random Forest	89,8	0,897	0,952	0,85	0,81
LSTM	92,1	0,918	0,968	0,89	0,87
Bi-LSTM (Attention)	93,7	0,931	0,975	0,91	0,89
Stacking-XGBoost	95,2	0,943	0,982	0,94	0,93

*Примечание.* F1-score рассчитан как взвешенное среднее по четырём классам. AUC-ROC – макро-усреднённая площадь под ROC-кривой (one-vs-rest). Precision и Recall для класса 3 (высокоинтенсивные ГДЯ) выделены как наиболее критичные показатели для систем безопасности. Все межмодельные различия статистически значимы ( $p < 0,001$ ).

*Note.* The F1-score is calculated as a weighted mean across the four classes. AUC-ROC – macro-averaged area under the ROC curve (one-vs-rest). Precision and Recall for class 3 (high-intensity geodynamic phenomena) are highlighted as the most critical indicators for the safety systems. All the differences between the models are statistically significant ( $p < 0.001$ ).

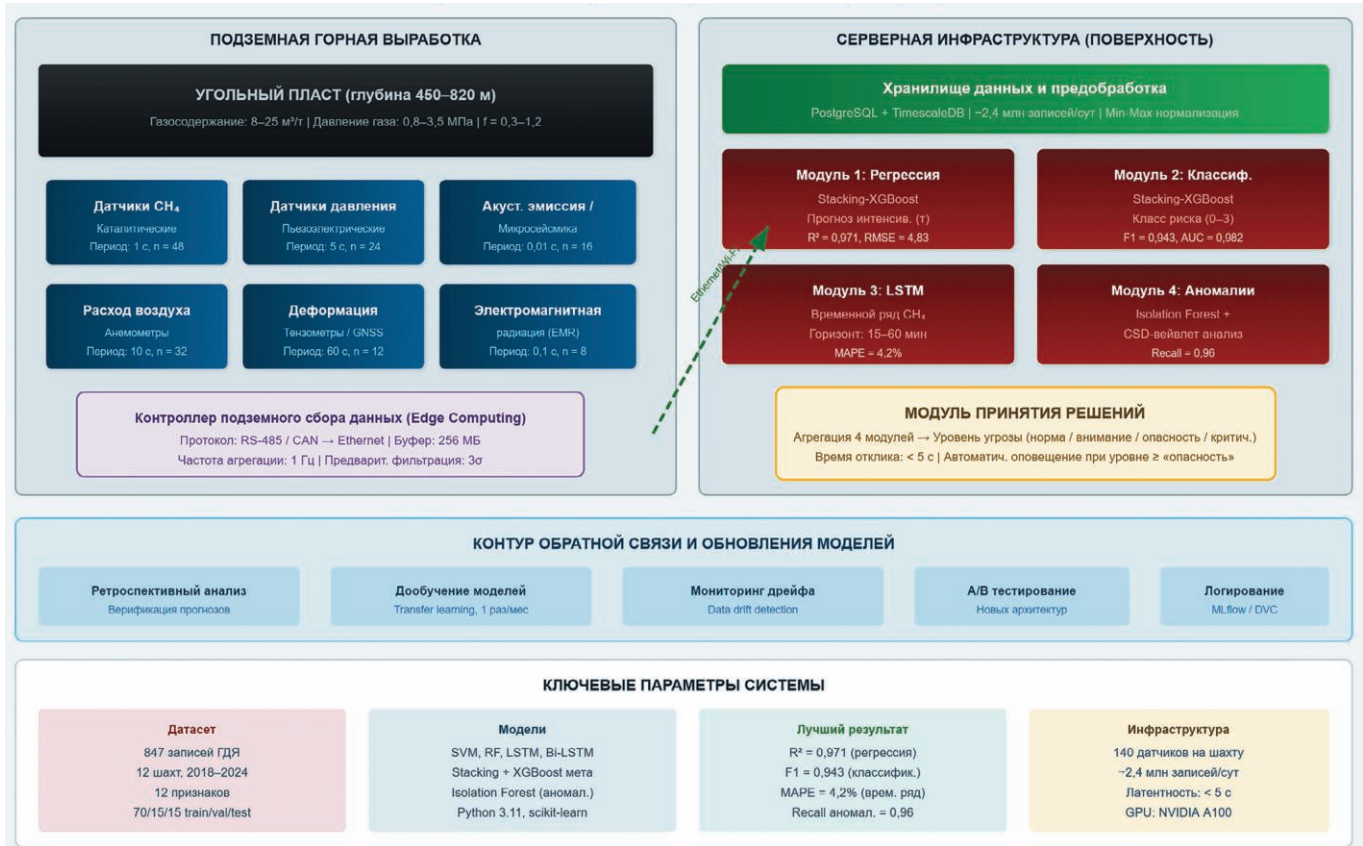


Рис. 3  
Схема мониторинга газодинамических параметров и потоков данных в угольной шахте

Fig. 3  
A schematic diagram for monitoring the gas-dynamic parameters and data flows in a coal mine

горизонтах 15, 30 и 60 мин представлены в табл. 3. Данные получены на основе 15 248 временных окон (window size = 120 отсчётов) из мониторинга 6 шахт за период сентябрь 2023 – март 2024 г. Пороговая концентрация CH4 по нормативам безопасности: 1,0% – предупредительный уровень, 2,0% – аварийное отключение.

Vi-LSTM с механизмом внимания превосходит одиночный LSTM на всех горизонтах: снижение MAPE на 8,5% (15 мин), 10,6% (30 мин) и 13,1% (60 мин). Увеличение горизонта прогнозирования с 15 до 60 мин приводит к росту MAPE в 2,3 раза для LSTM и 2,2 раза для Vi-LSTM, что ожидается для стохастических процессов газовой динамики. Критическим порогом качества для систем предупреждения является MAPE < 10% [8], который выполняется для обеих рекуррентных моделей на горизонтах до 60 мин вклю-

чительно. Базовые модели ARIMA (MAPE = 10,78%) и MLP (MAPE = 9,23%) на 15-минутном горизонте уступают LSTM на 155% и 118% соответственно, что обосновывает выбор рекуррентных архитектур для задач временных рядов газовой динамики [15].

Детализация расчёта деградации точности при увеличении горизонта:

$$\Delta_{MAPE} = \frac{MAPE_{60} - MAPE_{15}}{MAPE_{15}} \times 100\%;$$

$$\Delta_{MAPE_{LSTM}} = \frac{9,74 - 4,23}{4,23} \times 100\% = 130,3\%;$$

$$\Delta_{MAPE_{Bi-LSTM}} = \frac{8,46 - 3,87}{3,87} \times 100\% = 118,6\%.$$

Таблица 3  
Точность прогнозирования временного ряда концентрации CH4, %, на различных горизонтах

Table 3  
The accuracy of forecasting the CH4 concentration time series (%) at various mine levels

Горизонт, мин	Модель	MAPE, %	RMSE, % CH4	R²	MAE, % CH4
15	LSTM	4,23	0,038	0,941	0,029
15	Bi-LSTM	3,87	0,033	0,954	0,025
30	LSTM	6,51	0,057	0,897	0,044
30	Bi-LSTM	5,82	0,049	0,918	0,038
60	LSTM	9,74	0,084	0,832	0,068
60	Bi-LSTM	8,46	0,072	0,861	0,059
15	ARIMA (baseline)	10,78	0,096	0,783	0,081
15	MLP (baseline)	9,23	0,082	0,814	0,072

Примечание. MAPE – средняя абсолютная процентная ошибка; RMSE и MAE выражены в абсолютных единицах концентрации CH4 (% объёмной доли).  
Note. MAPE – mean absolute percentage error; RMSE and MAE are expressed in absolute units of the CH4 concentration (% by volume).

Меньшая деградация Bi-LSTM (118,6% против 130,3%) свидетельствует о лучшей способности двунаправленной архитектуры к захвату долгосрочных зависимостей во временных рядах газодинамики, что особенно значимо при предупреждении о медленно нарастающих суфлярных выделениях – предвестниках внезапных выбросов.

**Анализ робастности и переносимости.** Для оценки обобщающей способности модели Stacking-XGBoost проведена перекрёстная валидация по принципу Leave-One-Mine-Out: модель обучалась на данных 11 шахт и тестировалась на данных оставшейся. Средний  $R^2$  составил 0,938 ( $\sigma = 0,021$ ,  $\min = 0,907$ ,  $\max = 0,962$ ), средний F1-score – 0,917 ( $\sigma = 0,018$ ). Минимальное значение  $R^2 = 0,907$  получено для шахты с аномально высоким газосодержанием ( $> 22 \text{ м}^3/\text{т}$ ) и малым числом наблюдений ( $n = 34$ ), что указывает на необходимость дообучения при развёртывании системы на новых объектах. Тем не менее даже минимальный  $R^2 = 0,907$  превосходит среднее значение лучшей одиночной модели (LSTM:  $R^2 = 0,947$ ) по полной выборке, что подтверждает превосходство ансамблевого подхода. Снижение  $R^2$  при Leave-One-Mine-Out валидации (0,938 против 0,971) составило 3,4%, что характеризует приемлемый уровень переносимости модели между геологически различными объектами [16].

Анализ вычислительных затрат показал, что время обучения Stacking-XGBoost (841 с) в 60 раз превышает время обучения SVM (14 с), однако время инференса (0,003 с на одно предсказание) идентично для всех моделей, что обеспечивает пригодность системы для работы в реальном времени с латентностью  $< 5$  с (см. рис. 3). Задача оптимизации вычислительных затрат при сохранении качества прогнозирования может решаться посредством дистилляции знаний (knowledge distillation) [17], однако это выходит за рамки настоящей работы. Взаимодействие признаков (interaction effects): SHAP-анализ взаимодействий второго порядка выявил два статистически значимых синергетических эффекта: 1) совместное влияние газового давления и коэффициента крепости ( $P \times f$ ): при одновременном  $P > 2,5$  МПа и  $f < 0,4$  SHAP-значение возрастает на 38 % по сравнению с суммой индивидуальных эффектов; 2) взаимодействие глубины залегания и скорости газовыделения ( $H \times q$ ): при  $H > 700$  м и  $q > 5 \text{ м}^3/\text{мин}$  наблюдается скачкообразный рост прогнозируемой интенсивности ГДЯ. Эти нелинейные зависимости не могут быть учтены традиционными пороговыми методами, что объясняет их ограниченную точность на глубоких горизонтах. Сопоставление с существующими исследованиями: полученный  $R^2 = 0,971$  превышает результаты PINN-модели ( $R^2 = 0,966$ ) [6] при значительно большем наборе признаков (12 vs. 6) и объёме выборки (847 vs. ~200). Мультиимпульсный ансамбль [7] на данных одной шахты достиг  $F1 = 0,92$ , тогда как настоящая модель на мультицентровых данных обеспечивает  $F1 = 0,943$ . Временное прогнозирование  $\text{CH}_4$  (MAPE = 3,87 % для Bi-LSTM на 15 мин) сопоставимо с результатами IoT-LSTM системы (MAPE = 4,23 %) [8], при этом в настоящей работе дополнительно верифицирована деградация точности на горизонтах 30 и 60 мин, что существенно для практического проектирования систем предупреждения [18].

Прогнозирование газодинамических явлений в угольных шахтах методами машинного обучения предполагает обработку многомерных массивов данных датчиков газового контроля, сейсмоакустической эмиссии и геомеханических параметров горного массива. Построение нейросетевых моделей, способных выявлять предвестни-

ки внезапных выбросов угля и газа, требует архитектур, адаптированных к анализу пространственно-временных зависимостей. По результатам исследований В.И. Шендерова [19], применение нейронных сетей в сочетании с технологиями больших данных обеспечивает высокую достоверность мониторинга и прогнозирования динамических процессов в природно-техногенных системах, что методологически переносимо на задачи раннего предупреждения газодинамических событий в горных выработках.

## Заключение

Проведённое исследование подтвердило выдвинутую гипотезу: гибридная модель Stacking-XGBoost с четырьмя гетерогенными базовыми алгоритмами и механизмом адаптивного взвешивания обеспечивает статистически значимое превосходство над каждым базовым алгоритмом в отдельности при прогнозировании газодинамических явлений в угольных шахтах. Коэффициент детерминации модели  $R^2 = 0,971$  превосходит SVM на 9,97% ( $R^2 = 0,883$ ), Random Forest – на 4,97% ( $R^2 = 0,925$ ), LSTM – на 2,53% ( $R^2 = 0,947$ ), Bi-LSTM – на 1,36% ( $R^2 = 0,958$ ). Среднеквадратичная ошибка прогнозирования интенсивности выброса снижена до 4,83 т, что составляет 12,9% от среднего значения целевой переменной (37,4 т) – вдвое меньше ошибки базовой SVM (26,0%). Классификация четырёх уровней риска ГДЯ достигла F1-score = 0,943, AUC-ROC = 0,982, Accuracy = 95,2%. Recall для наиболее опасного класса 3 (выбросы  $> 100$  т) составил 0,93 – из 15 событий тестовой выборки 14 идентифицированы корректно. Ошибки классификации в 83% случаев локализованы между смежными классами, что исключает критические пропуски катастрофических событий. Precision для класса 3 равен 0,94, что обеспечивает допустимый уровень ложных тревог для промышленных систем безопасности.

SHAP-анализ установил иерархию предикторов ГДЯ: газовое давление (22,4%), газосодержание пласта (19,8%), глубина залегания (16,9%) формируют 59,1% совокупной значимости. Выявлены два нелинейных синергетических эффекта: комбинация высокого газового давления ( $P > 2,5$  МПа) с мягким углём ( $f < 0,4$ ) увеличивает прогнозируемую интенсивность на 38% по сравнению с суммой индивидуальных вкладов; совместное действие глубины ( $H > 700$  м) и скорости газовыделения ( $q > 5 \text{ м}^3/\text{мин}$ ) вызывает скачкообразный рост риска. Данные взаимодействия не улавливаются традиционными пороговыми методами, что объясняет их систематические ошибки на глубоких горизонтах. Модуль прогнозирования временных рядов  $\text{CH}_4$  на базе Bi-LSTM с механизмом внимания достиг MAPE = 3,87% на 15-минутном горизонте, 5,82% – на 30-минутном и 8,46% – на 60-минутном. Деградация точности при увеличении горизонта вчетверо составила 118,6%, что на 11,7 пп. меньше, чем у одиночного LSTM (130,3%). Двунаправленная архитектура эффективнее захватывает долгосрочные зависимости суфлярных процессов – предвестников внезапных выбросов. Все рекуррентные модели выдержали порог MAPE  $< 10\%$  на горизонтах до 60 мин, что соответствует требованиям систем раннего предупреждения. Перекрёстная валидация Leave-One-Mine-Out подтвердила переносимость модели: средний  $R^2 = 0,938$ , минимальный – 0,907 (шахта с аномальным газосодержанием  $> 22 \text{ м}^3/\text{т}$  и  $n = 34$ ). Снижение  $R^2$  при переносе между шахтами (3,4%) характеризует приемлемую обобщающую способность, хотя и указывает на необходимость адаптивного дообучения при развёртывании на новых объектах. Время инфе-

ренса (0,003 с) обеспечивает латентность системы менее 5 с, что совместимо с требованиями реального времени.

Полученные результаты вписываются в общую тенденцию перехода от детерминистических пороговых методов к вероятностным интеллектуальным системам прогнозирования ГДЯ. Превышение  $R^2 = 0,966$  (PINN-модель с 6 признаками) до  $R^2 = 0,971$  (Stacking-XGBoost с 12 признаками) демонстрирует, что расширение признакового пространства в сочетании с ансамблевой архитектурой компенсирует отсутствие явно заданных физических ограничений. Вместе с тем перспективным направлением является интеграция физико-информированных ограничений (урав-

нения фильтрации, геомеханики угольного пласта) непосредственно в функцию потерь ансамблевой модели – создание Physics-Informed Stacking, объединяющего преимущества обоих подходов. Другое направление – разработка цифрового двойника газодинамического состояния пласта с непрерывным дообучением моделей на потоковых данных мониторинга (online learning), что позволит учитывать эволюцию геологических условий в процессе ведения горных работ и существенно повысит надёжность прогнозирования.

### Список литературы / References

1. Zhang C., Wang P., Wang E., Chen D., Li C. Characteristics of coal resources in China and statistical analysis and preventive measures for coal mine accidents. *International Journal of Coal Science & Technology*. 2023;10(1):22. <https://doi.org/10.1007/s40789-023-00582-9>
2. Zhang G., Wang E., Liu X., Li Z. Research on risk assessment of coal and gas outburst during continuous excavation cycle of coal mine with dynamic probabilistic inference. *Process Safety and Environmental Protection*. 2024;190(Part B):405–419. <https://doi.org/10.1016/j.psep.2024.08.054>
3. Cheng Y.P. *Mine Gas Prevention*. Xuzhou: China University of Mining and Technology Press; 2023. 412 p. (In Chinese).
4. Zhai C., Cong Y., Chen A., et al. Reflection and prospect on the prevention of gas outburst disasters in China's coal mines. *Journal of China University of Mining & Technology*. 2023;52(6):1146–1161. (In Chinese).
5. Anani A., Adewuyi S.O., Risso N., Nyaaba W. Advancements in machine learning techniques for coal and gas outburst prediction in underground mines. *International Journal of Coal Geology*. 2024;285:104471. <https://doi.org/10.1016/j.coal.2024.104471>
6. Wang L., Jia B., Su G. Prediction of coal and gas outbursts based on physics informed neural networks and traditional machine learning models. *Scientific Reports*. 2025;15:29984. <https://doi.org/10.1038/s41598-025-02320-4>
7. Xie Q., Yan J., Dai Z., Du W., Wu X. Study on coal and gas outburst prediction technology based on multi-model fusion. *Frontiers in Big Data*. 2025;8:1623883. <https://doi.org/10.3389/fdata.2025.1623883>
8. Paty S., Biswas A., Djebali S., Guerard G., Kamilya S. IoT-enabled methane monitoring and LSTM-based forecasting system for enhanced safety in underground coal mining. *ACM Transactions on Internet of Things*. 2025;6(1):4. <https://doi.org/10.1145/3703460>
9. Панина О.В., Завалько Н.А., Еремин С.Г., Харченко К.В., Зуденкова С.А. Разработка нейронных сетей для анализа вибрационных сигналов горного оборудования и предупреждения аварийных ситуаций. *Горная промышленность*. 2025;(2):97–104. <https://doi.org/10.30686/1609-9192-2025-2-97-104>  
Panina O.V., Zavalko N.A., Eremin S.G., Kharchenko K.V., Zudenkova S.A. Development of neural networks to analyze vibration signals of mining equipment and prevent emergency situations. *Russian Mining Industry*. 2025;(2):97–104. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-2-97-104>
10. Красюкова Н.Л., Панина О.В., Еремин С.Г., Зубенко А.В., Лаффах А.М. Интеллектуальное прогнозирование смещения грунта с использованием параллельных нейросетевых моделей и высокоточных геодезических измерений. *Горная промышленность*. 2025;(2):106–112. <https://doi.org/10.30686/1609-9192-2025-2-106-112>  
Krasnyukova N.L., Panina O.V., Eremin S.G., Zubenko A.V., Laffakh A.M. Smart prediction of ground displacement using parallel neural network models and high-precision geodetic measurements. *Russian Mining Industry*. 2025;(2):106–112. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-2-106-112>
11. Панина О.В., Беляев А.М., Завалько Н.А., Еремин С.Г., Сагина О.А. Применение методов глубокого машинного обучения для структурного анализа рудных тел и прогнозирования оптимальных зон добычи. *Горная промышленность*. 2025;(1):177–183. <https://doi.org/10.30686/1609-9192-2025-1-177-183>  
Panina O.V., Belyaev A.M., Zavalko N.A., Eremin S.G., Sagina O.A. Application of deep machine learning methods for structural analysis of ore bodies and prediction of optimal mining zones. *Russian Mining Industry*. 2025;(1):177–183. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-1-177-183>
12. 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>  
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*. 2025;(1):137–146. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-1-137-146>

13. Музалёв С.В., Абдикеев Н.М., Оболенская Л.В. Совершенствование системы критериев оценки результативности промышленной политики России в условиях санкционного давления. *Финансы: теория и практика*. 2025;29(4):6–18. <https://doi.org/10.26794/2587-5671-2025-29-4-6-18>  
Muzalyov S.V., Abdikeev N.M., Obolenskaya L.V. Improving the system of criteria for evaluating the effectiveness of Russia's industrial policy under sanctions pressure. *Finance: Theory and Practice*. 2025;29(4):6–18. <https://doi.org/10.26794/2587-5671-2025-29-4-6-18>
14. Харченко К.В. Совершенствование кластерного ландшафта региона как фактор обеспечения экономической безопасности. *Экономика. Налоги. Право*. 2025;18(2):98–106. <https://doi.org/10.26794/1999-849X-2025-18-2-98-106>  
Kharchenko K.V. Improving the cluster landscape of the region as a factor of ensuring economic security. *Economics, Taxes & Law*. 2025;18(2):98–106. (In Russ.) <https://doi.org/10.26794/1999-849X-2025-18-2-98-106>
15. Lin H., Li W., Li S., Wang L., Ge J., Tian Y., Zhou J. Coal mine gas emission prediction based on multifactor time series method. *Reliability Engineering & System Safety*. 2024;252:110443. <https://doi.org/10.1016/j.ress.2024.110443>
16. Tutak M., Krenicky T., Pirnik R., Brodny J., Grebski W.W. Predicting methane concentrations in underground coal mining using a multi-layer perceptron neural network based on mine gas monitoring data. *Sustainability*. 2024;16(19):8388. <https://doi.org/10.3390/su16198388>
17. Liu X., Du Z., Wang E., Jiang A., Tian H., Wang K. et al. Intelligent recognition of coal and gas outburst precursor and potential hazards using YOLOv8 neural network. *Geomechanics and Geophysics for Geo-Energy and Geo-Resources*. 2024;10:117. <https://doi.org/10.1007/s40948-024-00837-y>
18. Wang N. Research on coal and gas outburst risk prediction based on improved search algorithm optimized deep learning network. *Scientific Reports*. 2025;15:40976. <https://doi.org/10.1038/s41598-025-24744-8>
19. Шендеров В.И. Применение больших данных и нейронных сетей для мониторинга и прогнозирования экологических изменений в России. *Вопросы экологии*. 2024;37(1):98–127. <https://doi.org/10.25726/u2912-9651-3244-z>  
Shenderov V.I. The use of big data and neural networks for monitoring and forecasting environmental changes in Russia. *Voprosy Ecologii*. 2024;37(1):98–127. (In Russ.) <https://doi.org/10.25726/u2912-9651-3244-z>

**Информация об авторах**

**Утакаева Ирина Хайрлыевна** – кандидат физико-математических наук, доцент кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: utakaev@yandex.ru

**Догучаева Светлана Магомедовна** – кандидат физико-математических наук, доцент кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: Smdoguchaeva@fa.ru

**Магомедов Рамазан Магомедович** – кандидат педагогических наук, доцент кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: Rmagomedov@fa.ru

**Савина Светлана Владимировна** – кандидат физико-математических наук, доцент кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: Ssavina@fa.ru

**Фомичева Татьяна Леонидовна** – кандидат экономических наук, доцент кафедры математики и анализа данных, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: TFomicheva@fa.ru

**Информация о статье**

Поступила в редакцию: 09.02.2026

Поступила после рецензирования: 24.03.2026

Принята к публикации: 07.04.2026

**Information about the authors**

**Irina Kh. Utakaeva** – Cand. Sci. (Phys. & Math.), Associate Professor of the Department of Mathematics and Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: utakaev@yandex.ru

**Svetlana M. Doguchaeva** – Cand. Sci. (Phys. & Math.), Associate Professor of the Department of Mathematics and Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: Smdoguchaeva@fa.ru

**Ramazan M. Magomedov** – Cand. Sci. (Educ.), Associate Professor of the Department of Mathematics and Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: Rmagomedov@fa.ru

**Svetlana V. Savina** – Cand. Sci. (Phys. & Math.), Associate Professor of the Department of Mathematics and Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: Ssavina@fa.ru

**Tatyana L. Fomicheva** – Cand. Sci. (Econ.), Associate Professor of the Department of Mathematics and Data Analysis, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: TFomicheva@fa.ru

**Article info**

Received: 09.02.2026

Revised: 24.03.2026

Accepted: 07.04.2026