

ПРОГНОЗ ДИНАМИЧЕСКИХ ПРОЯВЛЕНИЙ ГОРНОГО ДАВЛЕНИЯ НА ОСНОВЕ МИКРОСЕЙСМИЧЕСКОГО МОНИТОРИНГА И МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Деменков П.А., Силичева Е.Д.

Санкт-Петербургский горный университет императрицы Екатерины II, Санкт-Петербург

Ключевые слова: микросейсмический мониторинг, машинное обучение, динамические проявления горного давления, геомеханика, прогноз опасных состояний, удароопасность, рудные месторождения.

Аннотация. В условиях добычи на Хибинских апатит-нефелиновых месторождениях существует проблема динамических проявлений горного давления. Микросейсмический мониторинг способствует обнаружению зон повышенной удароопасности, но каталоги сейсмических событий строятся на основе работы инженеров и эмпирических данных. В таких условиях сложно выделить достоверные признаки опасных событий. В работе предлагается совершенствование метода прогноза динамических проявлений горного давления путем интегрирования в методы прогноза методов машинного обучения. Для анализа применялись четыре модели машинного обучения: логистическая регрессия, случайный лес, градиентный бустинг и многослойный перцептрон. Качество моделей оценивалось по метрикам для оценки моделей машинного обучения: PR-AUC, ROC-AUC и Brier Score с учётом временной валидации. Результаты показали, что наиболее информативными признаками являются энергетические характеристики событий и показатели локальной кластеризации. в пространственно-временном окне наблюдения. Ансамблевые модели (градиентный бустинг и логистическая регрессия) показали лучшие результаты и позволили выделить пространственно-временные области повышенного риска. Полученные результаты подтверждают прикладную ценность предлагаемого подхода для повышения надёжности мониторинга и формирования целевых мер по снижению риск-экспозиции в условиях сложных горно-геологических систем.

PREDICTION OF DYNAMIC MANIFESTATIONS OF ROCK PRESSURE BASED ON MICROSEISMIC MONITORING AND MACHINE LEARNING METHODS

Demenkov P.A., Silicheva E.D.

Empress Catherine II Saint Petersburg Mining University, Saint-Petersburg

Keywords: microseismic monitoring, machine learning, dynamic manifestations of rock pressure, geomechanics, prediction of hazardous conditions, impact hazard, ore deposits.

Abstract. In the conditions of production at the Khibiny apatite-nepheline deposits, there is a problem of dynamic manifestations of rock pressure. Microseismic monitoring helps identify high-risk areas, but catalogs of seismic events are based on the work of engineers and empirical data. In such conditions, it is difficult to identify reliable signs of dangerous phenomena. The article proposes to improve the methodology for predicting dynamic manifestations of mountain pressure by integrating machine learning methods into forecasting methods. Four machine learning models were used for the analysis: logistic regression, random forest, gradient boosting and multilayer perceptron. The quality of the models was assessed using indicators for evaluating machine learning models: PR-AUC, ROC-AUC and Brier Score, taking into account the verification time. The results showed that the most informative features are the energy characteristics of events and indicators of local clustering. in the window of space-time observation. Complex models (gradient acceleration and logistic regression) showed the best results and allowed us to identify spatio-temporal areas of increased risk. The results obtained confirm the practical value of the proposed approach for improving the reliability of monitoring and developing targeted measures to reduce the risk of exposure in complex mining and geological systems.

Введение

Динамическое проявление горного давления является серьёзным фактором риска при ведении подземных горных работ на склонных к удароопасности месторождениях [1]. На месторождениях апатит-нефелиновых руд Хибинского массива ведение очистных работ приводит к изменению напряжённо-деформированного состояния массива, формированию локальных зон концентрации напряжений и повышению вероятности развития процессов разрушения. Данные особенности требуют применения методов, позволяющих объективно

оценивать состояние массива и выявлять участки потенциального динамического проявления горного давления [2].

Микросейсмический мониторинг является одним из ключевых инструментов наблюдения за внутренними процессами в породном массиве [3]. Посредством датчиков АКСКП происходит фиксация мелкомасштабных проявлений горного давления (табл. 1). Однако каталоги таких событий представляют собой набор данных с высоким уровнем шума, который является неоднородным. В них трудно выделить устойчивые признаки, непосредственно указывающие на формирование опасных зон.

Табл. 1. Исходные данные: координаты (x,y,z), дата, время и энергия (J)

x	y	z	дата	время	энергия (J)
44655	27360	510	01.11.2009	0:00	$8,2 \cdot 10^3$
44392	27415	415	03.11.2009	23:37	$2 \cdot 10^3$
45265	27589	652	06.11.2009	21:27	$6,6 \cdot 10^4$
44586	27347	658	06.11.2009	21:37	$8,2 \cdot 10^3$
45392	27132	322	11.11.2009	0:40	$1,6 \cdot 10^4$
45288	27577	491	13.11.2009	16:23	$8,2 \cdot 10^3$

Прогноз удароопасности традиционно основывается на комплексном анализе геомеханических и геофизических параметров массива горных пород, а также на оценке напряжённо-деформированного состояния горного массива [4]. Основные методы прогнозирования можно разделить на региональные и локальные.

Региональные методы направлены на выявление зон повышенной сейсмической опасности на основе анализа геологической структуры, геотектонических нарушений и распределения напряжений в массиве. К ним относятся методы геодинамического районирования и микросейсмического мониторинга (рис. 1), позволяющие определить участки массива, подверженные динамическим явлениям [5].




Рис. 1. Сравнение фильтрованного и нефильтрованного сигнала аналогового датчика: по оси x – время в секундах, по оси y – амплитуда в мкВ [5]

Региональный прогноз служит основой для последующего уточнения зон риска на локальном уровне. Локальные методы прогнозирования основаны на прямых измерениях параметров состояния горных пород в конкретных участках массива. К ним относятся геофизические методы, такие как сейсмоакустический мониторинг, электрометрия и электромагнитное излучение, а также геомеханические методы, включающие оценку выхода керна и напряжённо-деформированного состояния по результатам бурения и испытаний пород [6]. Эти методы позволяют фиксировать признаки накопления повреждений и образования трещин (рис. 2), которые являются предвестниками динамических проявлений

горного давления [7]. Несмотря на значительный прогресс, существующие методы прогноза удароопасности обладают ограниченной точностью и высокой степенью неопределённости. В связи с этим актуальной остаётся задача совершенствования методов прогнозирования, в том числе за счёт интеграции традиционных подходов с современными технологиями анализа данных [8].




Рис. 2. Типизация керна в зависимости от трещиноватости [7]

Материалы и методы

Исследование основано на использовании данных, зарегистрированных на подземных выработках месторождений апатит-нефелиновых руд Хибинского массива. Месторождения характеризуются склонностью к удароопасности и сложностью структуры, включающей системы трещин [9], зоны тектонических нарушений и выраженную контрастность механических свойств пород. Микросейсмические события выступают естественным индикатором локального высвобождения накопленных напряжений и изменения напряжённо-деформированного состояния массива [10].

Исходные данные представлены параметрами, получаемые системой регистрации (датчики АКСП): момент времени возникновения, пространственные координаты, энергию, амплитудные и временные характеристики сигнала. Параметры имеют прямую связь с механикой разрушения: энергия связана с масштабом локального разрыва, продолжительность и частотный состав – с особенностями механизма источника, а пространственно-временная структура – с миграцией зон повышенной напряжённости [11]. Признаки не выбирались формально; использовались только характеристики, обладающие инженерным содержанием для анализа процессов нагружения и разгрузки массива [12].

Для анализа использовались алгоритмы машинного обучения, различающиеся по принципу работы [13]. Логистическая регрессия рассматривалась как базовая линейная модель (табл. 2), обеспечивающая прозрачную интерпретацию коэффициентов. Случайный лес и градиентный бустинг применялись благодаря устойчивости к шуму и способности выявлять нелинейные зависимости между признаками, что важно при работе с микросейсмическими данными [14]. Многослойный перцептрон использовался для анализа комплексных взаимосвязей, которые не всегда могут быть выявлены древообразными моделями, но глубина сети ограничивалась, чтобы избежать переобучения на сравнительно небольшом объёме данных [15]. Использование нескольких типов моделей необходимо для оценки стабильности результатов.

Оценка качества моделей проводилась по метрикам, отражающим особенности задачи прогнозирования редких периодов динамического проявления горного давления (табл. 2). Для инженерной оценки пригодности модели анализировалась точность при фиксированном уровне ложноположительных срабатываний [16].

Табл. 2. Метрики машинного обучения для оценки качества моделей

Метрика	Геомеханический смысл	Почему используется	Почему альтернативы не подходят
PR-AUC	Отражает способность находить редкие периоды активизации массива	Главная метрика для задач с редкими положительными примерами	Ассигасу и ROC-AUC скрывают ошибки по положительному классу
ROC-AUC	Характеризует отделимость состояний массива	Используется как дополнительная характеристика	Завышает качество при сильном дисбалансе классов
Ассигасу при фиксированном FPR	Соответствует требованиям эксплуатации систем безопасности	Отражает работу модели в реальных условиях	Обычная Ассигасу бесполезна при дисбалансе
Brier Score	Показывает корректность вероятностной оценки риска	Необходим для проверки калибровки вероятности	AUC-метрики не оценивают качество вероятности

Результаты

Анализ данных показал, что пространственно-временная структура микросейсмических событий действительно содержит признаки, связанные с формированием опасных состояний массива. При переходе массива в режим, характеризующийся повышенной концентрацией напряжений, наблюдалось увеличение энергетических характеристик событий, а также их локальная группировка в пределах ограниченных участков массива. Эти признаки являются традиционными индикаторами развития деформаций и подтверждают, что выбранные параметры несут инженерно значимую информацию.

Анализ исходных данных показал, что в них присутствует выраженная пространственно-временная неоднородность событий: фоновая активность представлена множеством малых по энергии сейсмических актов, при этом в отдельные интервалы появляются скопления событий с повышенной энергией. Для воспроизводимой проверки гипотезы о связи микросейсмике и развития локальных зон напряжения была использована гибридная формулировка целевой метки: положительный класс включает события с экстремально высокой энергией (≥ 99 -й перцентиль $\log_{10}(E)$) или события, принадлежащие к пространственным кластерам с высокой средней энергией (≥ 90 -й перцентиль $\text{cluster_mean_}\log E$).

Графический анализ позволил выделить несколько характерных закономерностей. Распределение энергии событий демонстрирует бимодальную структуру в периоды, предшествующие росту напряжений в массиве. В то время как фоновая активность характеризуется стабильным распределением с преобладанием малых энергий, в события, связанные с динамическим проявлением горного давления. Появляется группа событий с существенно более высокими значениями энергии. Это указывает на формирование концентратора напряжений и развитие процессов хрупкого разрушения в пределах ограниченного участка массива. На диаграмме временного хода энергии эта особенность выражается появлением последовательностей событий с возрастающей энергетикой, что соответствует нарастанию локальной деформации. На рисунке 3 представлен временной ряд значений $\log_{10}(\text{энергии})$ для всего каталога исходных данных, с пометкой положительных случаев по гибриднему критерию. На данном графике видно, что положительные события группируются в короткие последовательности, предвещая периоды повышенной локальной активности. Интерпретация: последовательный рост энергии ряда событий указывает на накопление деформаций в ограниченной точке массива и соответствует развитию локального концентратора напряжений.




Рис. 3. Энергия событий ($\log_{10}(E)$) во времени: тёмно-синие крестики – события, отнесённые к положительному классу по гибриднему критерию

Пространственная структура микросейсмических событий также изменялась в предаварийные периоды. На тепловых картах плотности эпицентров наблюдалось формирование устойчивых кластеров, расположенных в непосредственной близости к технологическим элементам системы разработки. При визуальном анализе траекторий смещения этих кластеров отмечалось постепенное смещение зон активности в направлении, соответствующем ожидаемому пути разгрузки массива, что подтверждает геомеханическую природу наблюдаемого процесса. Рисунок 4, а иллюстрирует пространственное распределение среднего значения $\log_{10}$ (энергии) в карте hexbin. Ядра повышенной средней энергии совпадают с кластерами положительных событий.

Для выделения геомеханически однородных зон применяется кластеризация (рис. 4, б).

На карте видны устойчивые кластеры, часть которых содержит большинство положительных событий по гибриднему критерию. Кластерная локализация совместно с энергетическими признаками усиливает доверие к выделяемым зонам риска, в отличие от единичных выбросов энергии.




Рис. 4. Карты: а) пространственное распределение среднего $\log_{10}(E)$ (hexbin); б) результат кластеризации DBSCAN: фон – шум/редкие события, голубые кластеры – устойчивые группы событий; крестиками отмечены положительные события

Для оценки качества моделей машинного обучения были построены кривые по метрикам [17], которые позволили наглядно сравнить способность различных алгоритмов выявлять редкие отдельные эпизоды повышения энергии проявления горного давления. Для сравнения алгоритмов на рисунке 5 и рисунке 6 приведены совмещённые ROC- и PR-кривые. PR-кривая является ключевой для оценки при редком положительном классе: она демонстрирует, какая доля действительно позитивных периодов будет найдена при заданной точности системы. В наших экспериментах градиентный бустинг показывал наилучшую PR-кривую, обеспечивая более высокий компромисс precision/recall, Random Forest уступал на высоких уровнях полноты, а MLP показывал более высокую вариативность при небольшом объёме обучающих данных. ROC-кривые дают дополнительное представление об общей отделимости классов, но без учёта дисбаланса они менее информативны для практических выводов.

Вероятностные прогнозы моделей были оценены по калибровочным диаграммам. Градиентный бустинг обеспечил наилучшую калиброванность вероятностей. Многослойный перцептрон, напротив, переоценивал вероятность наступления опасных периодов в области высоких значений, что свидетельствует о тенденции к завышению риска. Перечисленные особенности важны для практического применения, поскольку дают возможность оценить достоверность вероятностного прогноза, а не только его способность ранжировать периоды [18]. Используемые метрики описаны в таблице 3.




Рис. 5. Совмещённые ROC – кривые моделей




Рис. 6. Совмещённые PR – кривые моделей

Табл. 3. Оценка методов машинного обучения по метрикам

Модель	PR-AUC	ROC-AUC	Brier Score	Accuracy при FPR = 0,1
LogReg	0,18	0,77	0,192	0,41
Random Forest	0,39	0,86	0,148	0,58
Gradient Boosting	0,52	0,91	0,124	0,67
MLP	0,33	0,84	0,171	0,54

Интерпретация моделей показала, что наибольшее влияние на прогноз оказывают энергетические параметры событий, пространственная плотность очагов и характеристики формы сигнала, связанные с механизмом источника. Эти признаки подтверждают своё инженерное значение и согласуются с представлениями о механике разрушения, где накопление энергии, концентрация микротрещин и изменение характера излучения отражают переход массива из стабильного состояния в состояние готовности к нарушению. Результаты машинного анализа подтверждают физическую природу выбранных параметров и демонстрируют их прикладную пригодность.

Рисунок 7 содержит контурные карты вероятности, полученные с помощью моделей, – четыре панели, по одной для каждой модели. Карты визуально демонстрируют различия в «поведении» алгоритмов: бустинг формирует более локализованные «ядерные» зоны высокой вероятности, "лес" выдаёт более размытые, но устойчивые зоны, а MLP может формировать более сложные нелинейные структуры. Для инженера это важно: модели, которые дают слишком размытые облака вероятностей, усложняют принятие решений; модели с чётко локализованными высокими зонами легче сопоставлять с геомеханическими признаками (выемки, нарушения, контакты пород).

По результатам эксперимента градиентный бустинг показал наилучшие значения PR-AUC, что делает его предпочтительным для задач отбора при малой доле положительных периодов; Random Forest обеспечивает стабильность при шуме; логистическая регрессия выступает в качестве интерпретируемого базового алгоритма и может быть применена для верификации физической обоснованности решающей поверхности, что наглядно демонстрирует рисунок 8. Дополнительно для двух моделей (Random Forest и Gradient Boosting) были рассчитаны важность признаков: энергетические признаки ($\log_{10}(E)$), локальная плотность событий и пространственные градиенты вошли в список влияния на прогноз.




Рис. 7. Контурные карты вероятности (4 панели: LogReg, RF, GB, MLP): на каждой панели показано распределение предсказанной вероятности по XY-плоскости




Рис. 8. Карты вероятности для каждой из моделей

В заключение результатов отметим, что предложенная комбинация инженерных признаков и алгоритмов машинного обучения способна выделять пространственно-временные зоны повышенного риска, однако итоговая производственная привлекательность метода требует валидации с внешними независимыми данными и с учётом всех специфик конкретного месторождения.

Заключение и выводы

Несмотря на неполноту исходных данных, отсутствие части пространственной информации и разреженность опасных событий, статистические закономерности проявляются достаточно устойчиво. Локальные концентрации событий, чередование низкоэнергетических и высокоэнергетических периодов, а также формирование групповых всплесков указывают на наличие зон повышенных напряжений. Сейсмоакустическая активность демонстрирует признаки естественного предвестника динамических проявлений горного давления, однако сами по себе данные не позволяют однозначно оценить степень опасности без дополнительной обработки и анализа.

Модели машинного обучения, основанные на ансамблевых деревьях, оказались наиболее устойчивыми к структурному шуму и неполноте данных. Их способность выделять локальные зависимости и формировать структурно осмысленные поверхности вероятностей коррелирует с геомеханической природой процесса, где динамическая реакция массива обусловлена сочетанием литологических, тектонических и технологических факторов. Нейросетевые методы показали ограниченную применимость в условиях небольших выборок, что важно учитывать при проектировании систем прогноза на предприятиях с ограниченной историей наблюдений. Линейные методы оказались полезны лишь на этапе базового сравнения и не способны отражать реальное поведение массива (рис. 9).




Рис. 9. Калибровочные кривые моделей, демонстрирующие их способность к прогнозу

Важным результатом является то, что наиболее информативные признаки совпадают с геомеханически обоснованными параметрами: энергия событий, их пространственная концентрация и геометрия плотностных зон отражают физическую природу процесса лучше, чем любые вторичные статистические показатели (рис. 10).




Рис. 10. Весомость геомеханических статических и динамических признаков для построения моделей машинного обучения

Даже при значительных ограничениях входных данных удалось установить, что вероятностные карты риска, формируемые градиентным бустингом и случайным лесом, воспроизводят структуру активных зон гораздо точнее, чем это делает простая инженерная оценка исходных данных. Применение машинного обучения дополняет традиционные

геомеханические методы (табл. 3), а не заменяет их, обеспечивая количественную оценку вероятности перехода массива в опасное состояние, что особенно важно для эксплуатации месторождений Хибинского массива, склонных к динамическим проявлениям горного давления, что подтверждается статьями других авторов [19], направление является перспективным и открывает новые горизонты в решении задач геомеханики.

Список литературы

1. Захаров Л.А., Мартюшев Д.А., Пономарева И.Н. Прогнозирование динамического пластового давления методами искусственного интеллекта // Записки Горного института. – 2022. – Т. 253. – С. 23-32. – DOI: 10.31897/PMI.2022.11.
2. Господариков А.П., Зацепин М.А., Киркин А.П. Определение потенциала удароопасности горных пород Норильского промышленного района // Записки Горного института. – 2025. – Т. 272. – С. 83-90.
3. Разумов Е.Е., Простов С.М., Шабанов Е.А. Региональный, локальный и текущий прогноз удароопасности участков угольного пласта на основе сейсмического мониторинга // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2024. – Т. 335, №8. – С. 174-186. – DOI: 10.18799/24131830_2024_8_4420.
4. Петров Д.Н., Абашин В.И., Карасев М.А., Селихов А.А. Исследование возможности применения методов неразрушающего контроля для оценки прочностных свойств горных пород в условиях подземного рудника Гремячинского месторождения // Горный информационно-аналитический бюллетень. – 2024. – №12-1. – С. 227-244. – DOI: 10.25018/0236_1493_2024_121_0_227.
5. Зайцев Д.Л., Брыксин В.М., Белотелов К.С., Компаниец Ю.И., Яковлев Р.Н. Алгоритмы и измерительный комплекс классификации источников сейсмических сигналов, определения расстояния и азимута до пункта возбуждения поверхностных волн // Информатика и автоматизация. – 2022. – Т. 21, №6. – С. 1211-1239. – DOI: doi.org/10.15622/ia.21.6.5.
6. Блинов П.А., Силичев Н.М., Никишин В.В., Гореликов Г.Г. Обоснование и разработка отклонителя непрерывного действия с полным отбором керна для бурения геологоразведочных скважин // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2025. – Т. 336, №7. – С. 17-28. – DOI: 10.18799/24131830_2025_7_4780.
7. Ауханов Я.Г., Ситдикова Л.М., Исаев Г.Д. Визуальная оценка трещиноватости керна материала с элементами геодинамической интерпретации (Западная Сибирь) // Георесурсы. – 2014. – №1(56). – С. 48-50.
8. Гусев В.Н., Одинцов Е.Е., Жерлыгина Е.С. Расчет сдвижений и деформаций массива горных пород с учетом натурных данных // Горный журнал. – 2025. – №4. – С. 18-25. – DOI: 10.17580/gzh.2025.04.03.
9. Господариков А.П., Ревин И.Е., Морозов К.В. Композитная модель анализа данных сейсмического мониторинга при ведении горных работ на примере Кукушумчоррского месторождения АО «Апатит» // Записки Горного института. – 2023. – Т. 262. – С. 571-580. DOI: 10.31897/PMI.2023.9.
10. Козырев А.А., Каспарьян Э.В., Федотова Ю.В., Кузнецов Н.Н. Оценка степени удароопасности скальных горных пород на основе результатов лабораторных испытаний // Вестник Мурманского государственного технического университета. – 2019. – Т. 22, №1. – С. 138-148. – DOI: 10.21443/1560-9278-2019-22-1-138-148.
11. Tadeusiewicz R. Neural networks in mining sciences—general overview and some representative examples. // Archives of Mining Sciences. 2015, vol. 60, no. 4, pp. 971-984. DOI: 10.1515/amsc-2015-0064.
12. Дягилева А.В., Пылов П.А., Майтак Р.В., Николаева Е.А. Метрики и критерии качества моделей глубокого обучения для оценки точности прогнозирования сейсмического удара высокой энергии // Вестник Научного центра ВостНИИ по промышленной и экологической безопасности. – 2025. – №3. – С. 21-34. – DOI: 10.25558/VOSTNI.2025.47.21.003.
13. Сергунин М.П., Еременко В.А. Обработка структурных геологических моделей алгоритмами искусственного интеллекта // Горный информационно-аналитический бюллетень. – 2023. – №9. – С. 56-67. – DOI: 10.25018/0236_1493_2023_9_0_56.
14. Cai M. Rockburst risk control and mitigation in deep mining // Deep Resources Engineering. 2024, vol. 1, no. 2, pp. 100019. DOI: 10.1016/j.deepr.2024.100019.
15. Грунин А.П., Константинов А.В., Ломов М.Е. Передовые методы и средства геомеханического мониторинга на основе технологий машинного обучения // Горный информационно-аналитический бюллетень. – 2025. – №12-2. – С. 166-179. – DOI: 10.25018/0236_1493_2025_122_0_166.
16. Ahmad M. Katman H. Y., Al-Mansob R. A., Ahmad F., Safdar M., Alguno A. C. Prediction of rockburst intensity grade in deep underground excavation using adaptive boosting classifier // Complexity. 2022, vol. 2022, no. 1, pp. 6156210. DOI: 10.1155/2022/6156210.
17. Zhou J., Koopalipoor M., Li E., Armaghani D. J., Prediction of rockburst risk in underground projects developing a neuro-bee intelligent system // Bulletin of Engineering Geology and the Environment. 2020, vol. 79, no. 8, pp. 4265-4279. DOI: 10.1007/s10064-020-01788-w.
18. Жилев Р.А. Построение самоорганизующейся карты Кохонена (SOM) для прогнозирования типов селевых потоков // Известия Кабардино-Балкарского научного центра РАН. – 2024. – Т. 26. – №5. – С. 129-137. – DOI: 10.35330/1991-6639-2024-26-5-129-137.
19. Господариков А.П., Морозов К.В., Ревин И.Е. О методе обработки данных сейсмического и деформационного мониторинга при ведении подземных горных работ на примере Кукушумчоррского

References

1. Zakharov L.A., Martyshev D.A., Ponomareva I.N. Predicting dynamic formation pressure using artificial intelligence methods. // Journal of Mining Institute. 2022, vol. 253, pp. 23-32. DOI: 10.31897/PMI.2022.11.
2. Gospodarikov A.P., Zatsepin M.A., Kirkin A.P. Determination of impact hazard potential of rocks in the Norilsk Industrial Region // Journal of Mining Institute. 2025, vol. 272, pp. 83-90.
3. Razumov E.E., Prostov S.M., Shabanov E.A. Regional, local and current forecast of the impact hazard of coal seam sites based on seismic monitoring. // Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering, 2024, vol. 335, no. 8, pp. 174-186. DOI: 10.18799/24131830/2024/8/4420.
4. Petrov D.N., Abashin V.I., Karasev M.A., Selikhov A.A. Non-destructive testing applicability in rock mass strength estimation in underground mine at the Greymachinsk deposit // Mining information and analytical bulletin. 2024, no. 12-1, pp. 227-244. DOI: 10.25018/0236_1493_2024_121_0_227.
5. Zaitsev D.L., Bryksin V.M., Belotelov K.C., Kompaniets Yu.I., Yakovlev R.N. Algorithms and Measuring Complex for Classification of Seismic Signal Sources, Determination of Distance and Azimuth to the Point of Excitation of Surface Waves // Informatics and Automation. 2022, vol. 21, pp. 1211-1239. DOI: 10.15622/ia.21.6.5.
6. Blinov P.A., Silichev N.M., Nikishin V.V., Gorelikov V.G. Justification and development of a continuous deflector with full core sampling for drilling exploration wells // Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering. 2025, vol. 336, no. 7, pp. 17-28. DOI: 10.18799/24131830/2025/7/4780.
7. Aukhatov Ya.G., Sitdikova L.M., Isaev G.D. Visual assessment of fracturing of core material with elements of geodynamic interpretation (Western Siberia) // Georessory. 2014, no. 1(56), pp. 48-50.
8. Gusev V.N., Odintsov E.E., Zherlygina E.S. Calculation of shifts and deformations of the rock mass considering field data // Mining Journal. 2025, no. 4, pp. 15-25. DOI: 10.17580/gzh.2025.04.03.
9. Gospodarikov A.P., Revin I.E., Morozov K.V. Composite model of seismic monitoring data analysis during mining operations on the example of the Kukisvumchorskoye deposit of AO Apatit // Journal of Mining Institute. 2023, vol. 262, pp. 571-580. DOI: 10.31897/PMI.2023.9.
10. Kozyrev A.A., Kasparyan E.V., Fedotova Iu.V., Kuznetsov N.N. (2019). Estimating the rockburst hazard of hard rocks based on laboratory test results // Bulletin of the Murmansk State Technical University. 2019, vol. 22, no. 1, pp. 138-148. DOI: 10.21443/1560-9278-2019-22-1-138-148.
11. Tadeusiewicz R. Neural networks in mining sciences—general overview and some representative examples. // Archives of Mining Sciences. 2015, vol. 60, no. 4, pp. 971-984. DOI: 10.1515/amsc-2015-0064.
12. Diaghileva A.V., Pylov P.A., Maitak R.V., Nikolaeva E.A. Metrics and quality criteria of deep learning models for evaluating the accuracy of forecasting a high-energy seismic shock // Bulletin of Scientific Centre VostNII for Industrial and Environmental Safety. 2025, no. 3, pp. 21-34. DOI: 10.25558/VOSTNII.2025.47.21.003.
13. Sergunin M.P., Eremenko V.A. Application of artificial intelligence algorithm in processing structural geological models // Mining information and analytical bulletin. 2023, no. 9, pp. 56-67. DOI: 10.25018/0236_1493_2023_9_0_56.
14. Cai M. Rockburst risk control and mitigation in deep mining // Deep Resources Engineering. 2024, vol. 1, no. 2, pp. 100019. DOI: 10.1016/j.deepre.2024.100019.
15. Grunin A.P., Konstantinov A.V., Lomov M.E. Advanced methods and tools for geomechanical monitoring based on machine learning technologies // Mining information and analytical bulletin. 2025, no. 12-2, pp. 166-179. DOI: 10.25018/0236_1493_2025_122_0_166.
16. Ahmad M., Katman H. Y., Al-Mansob R. A., Ahmad F., Safdar M., Alguno A. C. Prediction of rockburst intensity grade in deep underground excavation using adaptive boosting classifier // Complexity. 2022, vol. 2022, no. 1, pp. 6156210. DOI: 10.1155/2022/6156210.
17. Zhou J., Koopialipour M., Li E., Armaghani D. J., Prediction of rockburst risk in underground projects developing a neuro-bee intelligent system // Bulletin of Engineering Geology and the Environment. 2020, vol. 79, no. 8, pp. 4265-4279. DOI: 10.1007/s10064-020-01788-w.
18. Zhilov R.A. Construction of Kohonen self-organizing map (SOM) for prediction of mudflow types // News of the Kabardino-Balkarian Scientific Center of RAS. 2024, vol. 26, no. 5, pp. 129-137. DOI: 10.35330/1991- 6639-2024-26-5-129-137.
19. Gospodarikov A. P., Morozov K.V., Revin I.E. On the method of processing seismic and deformation monitoring data during underground mining operations using the example of the Kikusvumchorskoye deposit of JSC Apatit // Mining information and analytical bulletin. 2019, no. 8, pp. 157-168. DOI: 10.25018/0236-1493-2019-08-0-157-168.

Сведения об авторах:

Information about authors:

Деменков Петр Алексеевич – доктор технических наук, доцент, профессор кафедры строительства горных предприятий и подземных сооружений, декан строительного факультета	Demenkov Petr Alekseevich – doctor of technical sciences, associate professor, professor of the Department of construction of mining enterprises and underground structures, dean of the Faculty of civil engineering
Силичева Екатерина Дмитриевна – аспирант	Silicheva Ekaterina Dmitrievna – postgraduate student
romnva@yandex.ru	

Получена 11.06.2026