

ПЕРЕДОВЫЕ МЕТОДЫ И СРЕДСТВА ГЕОМЕХАНИЧЕСКОГО МОНИТОРИНГА НА ОСНОВЕ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ

А.П. Грунин¹, А.В. Константинов¹, М.Е. Ломов¹

¹ Институт горного дела Дальневосточного отделения РАН, Хабаровск, Россия,
e-mail: lexx188@mail.ru

Аннотация: При геомеханическом мониторинге удароопасных месторождений современные системы контроля горного давления регистрируют значительные объемы данных. Для обработки таких массивов данных необходимым становится применение передовых методов и средств на основе технологий машинного обучения. Работа посвящена обработке данных системы «Prognoz-ADS» Николаевского месторождения. Иерархический подход к обработке данных требует средств автоматической классификации данных нижнего уровня – зарегистрированных импульсов. Импульсы делятся на три категории: естественная акустическая эмиссия, сигналы от буровых работ, а также сигналы, возникающие при проведении взрывных работ. В процессе исследования рассмотрены основные этапы проектирования классификационной модели машинного обучения. Полученная модель достигла точности выше 95%, что позволяет получать более полную информацию о состоянии породного массива и способствует повышению безопасности ведения горных работ.

Ключевые слова: геомеханика, удароопасность, акустическая эмиссия, геомеханический мониторинг, автоматизация, цифровые технологии, машинное обучение, случайный лес

Для цитирования: 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.

Advanced methods and tools for geomechanical monitoring based on machine learning technologies

A.P. Grunin¹, A.V. Konstantinov¹, M.E. Lomov¹

¹ Mining Institute of the Far Eastern Branch of Russian Academy of Sciences,
Khabarovsk, Russia, e-mail: lexx188@mail.ru

Abstract: In the geomechanical monitoring of rockburst-hazardous deposits, modern rock pressure control systems record significant volumes of data. Processing such large data volumes necessitates the use of advanced methods and tools based on machine learning technologies. This work focuses on processing data from the «Prognoz-ADS» system at the Nikolaevskoye deposit. The hierarchical approach to data processing requires automatic classification of lower-level data – recorded impulses. The impulses are divided into three categories: natural acoustic emission, signals from drilling operations, and signals arising from blasting operations. The study examines the main stages of designing a machine learning classification model. The resulting model achieved accuracy exceeding 95%, enabling more comprehensive information on the state of the rock mass to be obtained and contributing to enhanced safety and efficiency of mining operations.

Key words: geomechanics, rockburst hazard, acoustic emission, geomechanical monitoring, automation, digital technologies, machine learning, random forest

For citation: Grunin A. P., Konstantinov A. V., Lomov M. E. Advanced methods and tools for geomechanical monitoring based on machine learning technologies. *MIAB. Mining Inf. Anal. Bull.* 2025;(12-2):166-179. [In Russ]. DOI: 10.25018/0236_1493_2025_122_0_166.

Введение

В техногенного воздействия горных работ, при извлечении и перемещении значительных объемов горной массы, формируются значительные по площади выработанные пространства. При этом иногда на порядок и более увеличивается скорость деформирования пород, по сравнению с ее естественным уровнем. На нее оказывают влияние динамические воздействия от взрывных работ и сезонно — обводненность породного массива [1].

Техногенная сейсмичность является отражением эволюции напряженно-деформированного состояния геологической среды в природно-технических системах, так же как тектоническая сейсмичность является следствием разрядки накопившихся высоких напряжений в отдельных участках литосферы. Убедительным свидетельством этому является изменение параметров техногенной сейсмичности на рудниках в связи с увеличением глубины и объемов горных работ и соответствующим усложнением геомеханической ситуации. Анализ потока сейсмических событий

показывает, что не менее половины их источников являются внутренними разрушениями в массиве пород, не проявляющимися в горных выработках.

Основными факторами, определяющими проявление сейсмических событий в массиве, а также, соответственно, горных ударов и техногенных землетрясений, являются зоны концентрации естественных напряжений в нетронутом массиве, напряжений вблизи очистных пространств и тектонических нарушений, массовые взрывы, водопритоки в выработках. Мощные технологические взрывы в ряде случаев вызывают явление техногенной афтершоковой сейсмичности, поскольку они играют роль спусковых механизмов для различного рода динамических явлений в массиве пород. Указанные факторы требуют осуществления контроля состояния горных массивов на разных масштабных уровнях, от локального [2], до регионального [3, 4].

Система «Prognoz-ADS»

Автоматизированная система контроля горного давления «Prognoz-ADS»,

разработанная в ИГД ДВО РАН [5] и применяемая на ряде удароопасных месторождений России, предназначена для непрерывной регистрации в массиве горных пород импульсов акустической эмиссии (являющихся следствием упругого разрушения горных пород) в частотном диапазоне 0,2...12 кГц, определения их параметров (энергии, координат, спектральных и иных характеристик акустических событий) и представления результатов мониторинга в виде каталогов, карт, графиков и оценок с применением современных алгоритмов и программных средств. Специализированный программный комплекс системы позволяет рассчитывать, выделять и контролировать параметры потенциаль-

но удароопасных зон в массиве горных пород, проводить прогнозную оценку геомеханического состояния массива горных пород. На рис. 1 представлено схематическое представление основных элементов системы «Prognoz-ADS».

Высокий частотный диапазон системы с одной стороны позволяет регистрировать низкоэнергетические очаги акустической активности, но с другой приводит к регистрации большого количества сигналов техногенного происхождения, возникающих вследствие активной разработки полезных ископаемых. Основной вклад в формирование техногенных помех вносят буровзрывные работы. Количество таких акустических сигналов в отдельные периоды

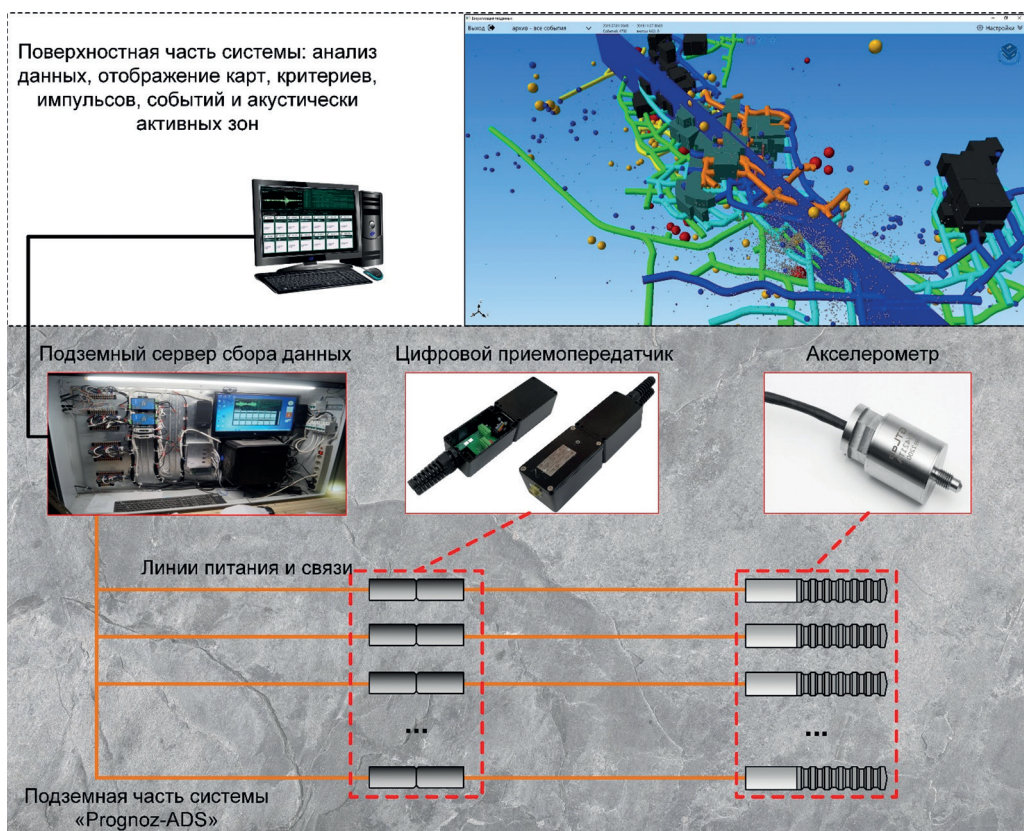


Рис. 1. Схематическое представление основных элементов системы «Prognoz-ADS»

Fig. 1. Schematic representation of the Prognoz-ADS system main elements



Рис. 2. Основные этапы в проектировании классифицирующей модели машинного обучения
 Fig. 2. Key steps in designing a machine learning classification model

времени может достигать 90% от всего объема данных, регистрируемых системой «Prognoz-ADS».

В Дальневосточном регионе разрабатывается ряд рудных месторождений, опасных по горным ударам. Одними из наиболее сложных является месторождение Николаевское. По результатам выполненных в предыдущие годы исследований установлено, что склонные и опасные по горным ударам месторождения Дальневосточного региона находятся в пределах тектонически активной Амурской плиты, характеризующейся высокой структурной неоднородностью, тектонической раздробленностью и наличием областей повышенных напряжений. Система «Prognoz-ADS» установлена на Николаевском месторождении с 2012 г. и фиксирует значительный объем сигналов [6, 7]. Среднегодовой объем сигналов составляет около 3 млн.

Для анализа столь обширного объема используется иерархический подход к обработке данных. На нижнем уровне иерархии располагаются импульсы — это первичные данные, принятые датчиками. Далее идут события — объединенные во времени и пространстве импульсы, соответствующие одному источнику акустической активности [8]. Объемные области, внутри которых формируются события определенного типа образуют акустически активные зоны.

На основе информации об акустически активных зонах, а также дополнительных данных, возможно построение прогностических моделей горных ударов.

Для точного прогнозирования и контроля удароопасности критически важна классификация акустических импульсов на нижнем уровне иерархии. Учитывая масштабы мониторинга и возрастающие объемы данных, ручная обработка специалистами становится неэффективной — это обусловило разработку автоматизированной системы классификации на основе методов машинного обучения [9, 10].

Представленный подход подразумевает разделение импульсов на три категории: естественная акустическая эмиссия, сигналы от буровых и других работ в зоне чувствительности датчиков, а также сигналы, возникающие при проведении взрывных работ в пределах действия датчиков.

На рис. 2 представлены основные этапы в проектировании классифицирующей модели машинного обучения.

Создание обучающей выборки данных

Для создания обучающей выборки данных была использована база данных системы «Prognoz-ADS» Николаевского рудника за 2022 г. Выбор этого временного интервала обусловлен тем, что в

течение года на руднике активно функционировало около 20 датчиков, что дает достаточный репрезентативный объем данных.

Для построения выборки применялись опыт специалистов по ручной обработке сигналов в базе данных и специально разработанное ПО GeoFiltration. Интерактивные графики GeoFiltration позволяют отображать сигналы и их параметры на временной шкале. Такая визуализация удобна для выявления характерных закономерностей, например, сигналов, вызванных буровыми или взрывными работами. Графики позволяют определять типы импульсов вручную или методами кластерного анализа, что делает GeoFiltration удобным инструментом для формирования обучающих выборок [11, 12].

На рис. 3 представлен пример, позволяющий увидеть размеченный интервал времени, на котором встречаются как акустические импульсы, возникшие после взрывных работ (обозначены зеленым цветом), так и импульсы, источником которых является буровое оборудование (обозначены оранжевым цветом на рисунке).

На оси Y отображен параметр «время между соседними импульсами». Рисунок наглядно демонстрирует, что интенсивность естественной акустики постепенно снижается после взрыва, а буровые импульсы имеют несколько фиксированных уровней интенсивности. Эти примеры были добавлены в обучающую выборку для того, чтобы модель научилась выявлять и классифицировать подобные участки на новых данных.

На рис. 4 представлены импульсы от взрывных работ, выделенные при создании обучающей выборки за 2022 г. На оси Y отложено число секунд от начала суток. И, как видно из рисунка, большинство импульсов расположены в интервалах 20 000–30 000 с и 60 000–70 000 с от начала суток (что соответствует примерно 5:30–8:20 и 16:40–19:20). Эта особенность объясняется тем, что взрывные работы проводятся в две смены в указанные периоды. Однако наблюдаются также импульсы от взрывных работ и в невзрывное время. Эти примеры также были добавлены в обучающую выборку.

Состав обучающей выборки, сформированной на основе данных Никола-




Рис. 3. Пример размеченных импульсов естественной акустической эмиссии и буровых импульсов
Fig. 3. Example of labeled natural acoustic emission pulses and drilling pulses




Рис. 4. Импульсы от взрывных работ, выделенные при создании обучающей выборки за 2022 г.
 Fig. 4. Blast pulses extracted during the creation of the training dataset for 2022

евского рудника включает 15 195 взрывных импульсов, 102 676 буровых импульсов, 74 850 импульсов естественной акустической эмиссии. Процентное соотношение импульсов каждого класса представлено на рис. 5. В выборке имеется дисбаланс экземпляров каждого класса, поэтому при обучении применялись методы балансировки классов.

Определение признаков

Следующим этапом является определение пространства признаков. В базе данных системы «Prognoz-ADS» имеется ряд признаков, которые рассчитываются на стороне регистрирующего датчика в момент регистрации каждого импульса. Расчет этих признаков производится в реальном времени, после чего они записываются в базу данных. Список признаков приведен в табл. 1.

Для надежной классификации сигналов акустической эмиссии может потребоваться расширение списка признаков. Дополнительные признаки могут быть рассчитаны исходя из показателя времени регистрации импульса. Список дополнительных признаков приведен в табл. 2.

При подготовке признакового пространства модели машинного обучения необходимо провести анализ распределения данных и сделать выводы взаимосвязях между признаками в наборе данных. Распределения значений признаков, разделенные по категориям типа импульса, помогают увидеть, как различные группы соотносятся друг с дру-




Рис. 5. Импульсы от взрывных работ, выделенные при создании обучающей выборки за 2022 г.
 Fig. 5. Blast pulses extracted during the creation of the training dataset for 2022

Таблица 1

Характеристика признаков, рассчитываемых на стороне регистрирующего датчика системы контроля горного давления «Prognoz-ADS»**Characteristics of the features calculated on the side of the recording sensor of the Prognoz-ADS rock pressure monitoring system**

Наименование признака	Определение
Амплитуда	Максимальное значение амплитуды в течение всей продолжительности регистрации сигнала
Длительность	Продолжительность сигнала
Длительность фронта	Интервал времени от момента начала сигнала до момента регистрации максимальной амплитуды
Порог регистрации	Уровень сигнала, при котором сработал алгоритм обнаружения
Площадь	Сумма модулей амплитуд в течении всей продолжительности регистрации сигнала
MARSE	Сумма квадратов амплитуд в течении всей продолжительности регистрации сигнала

гом. Например, различия в распределении значений между категориями могут указывать на важные закономерности, которые стоит учитывать при дальнейшей аналитике или моделировании. Также анализ распределений позволяет понять необходимость масштабирования отдельных признаков (нормализация, логарифмирование).

При большом количестве признаков возможно применение специальных алгоритмов снижения размерности данных. Алгоритмы снижения размерности, такие как UMAP, PCA [13] и t-SNE [14], играют важную роль в анализе признаков

для выбора оптимальной модели обучения. В задачах с большим количеством признаков данные могут содержать как полезные, так и избыточные или коррелированные признаки, что усложняет обучение моделей и может привести к переобучению или снижению эффективности модели. Снижение размерности помогает сократить размерность пространства без значительных потерь в информации. Это помогает лучше понять структуру данных, выявить скрытые паттерны и кластеры, что дает ценную информацию для выбора подходящей модели обучения. На-

Таблица 2

Характеристика дополнительных признаков**Characteristics of additional features**

Наименование признака	Определение
Глобальная плотность импульсов	Число импульсов, зарегистрированных всеми доступными геофонами в интервале времени T от момента регистрации исходного импульса
Время до ближайшего импульса	Параметр, позволяющий определять периодичность в поступлении сигналов и тем самым определять периодические события, которые характерны для буровой активности
Локальная плотность импульсов	Число импульсов, зарегистрированных конкретным геофоном в интервале времени T от момента регистрации исходного импульса

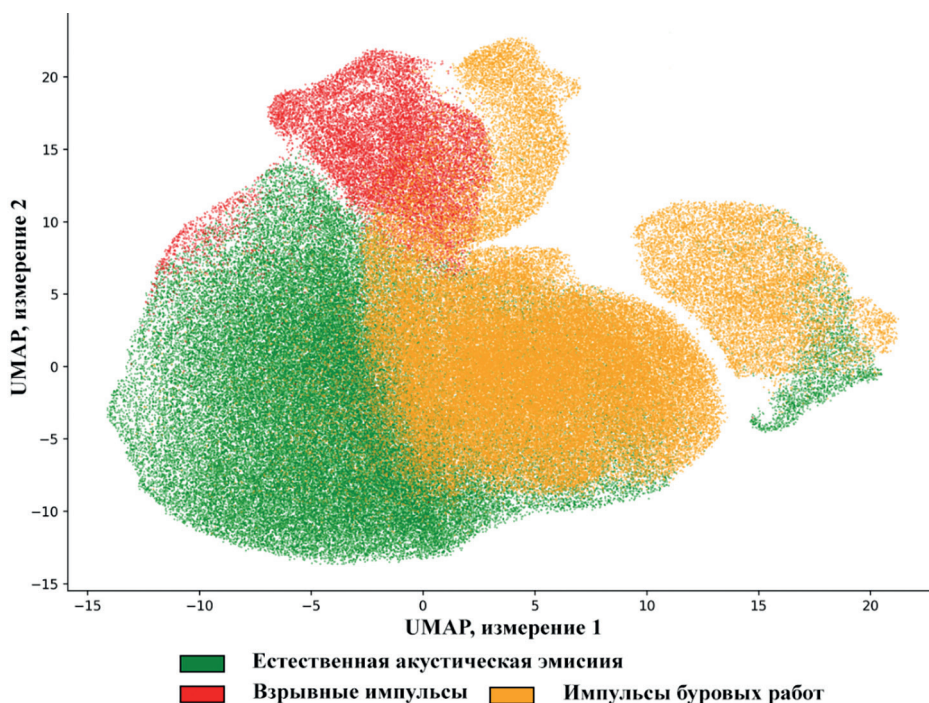


Рис. 6. График свернутого в двумерное пространство алгоритмом UMAP набора 9 признаков
 Fig. 6. Plot of a set of 9 features folded into a two-dimensional space by the UMAP algorithm

пример, если данные хорошо разделяются в низкоразмерном пространстве, то это свидетельствует как о качественной подготовке обучающей выборки, так и о том, что применение модели машинного обучения окажется эффективным.

UMAP (Uniform Manifold Approximation and Projection) [15] — это алгоритм для снижения размерности данных, который сохраняет топологическую структуру многомерного пространства при проекции в пространство с меньшим числом измерений. Его основная идея заключается в том, чтобы приблизить исходное многомерное пространство к низкоразмерному, при этом максимально сохраняя глобальные и локальные взаимосвязи между точками.

На рис. 6 представлен график свернутого в двумерное пространство алгоритмом UMAP набора 9 признаков. Классы естественной акустической эмис-

сии, буровых работ и взрывных работ хоть и разделены, но имеют пересечения. Это свидетельствует о том, что для эффективного обучения могут потребоваться более сложные модели, такие как случайные леса или нейронные сети.

Выбор и обучение модели

На этапе выбора и обучения модели была протестирована одна из моделей машинного обучения на размеченной части базы данных. В качестве модели был выбран метод случайного леса [16].

Случайный лес — это ансамблевый метод, который строит множество решающих деревьев и использует их для совместного принятия решения. Алгоритм работает следующим образом: каждое отдельное дерево обучается на случайном подмножестве данных и случайном подмножестве признаков. Это

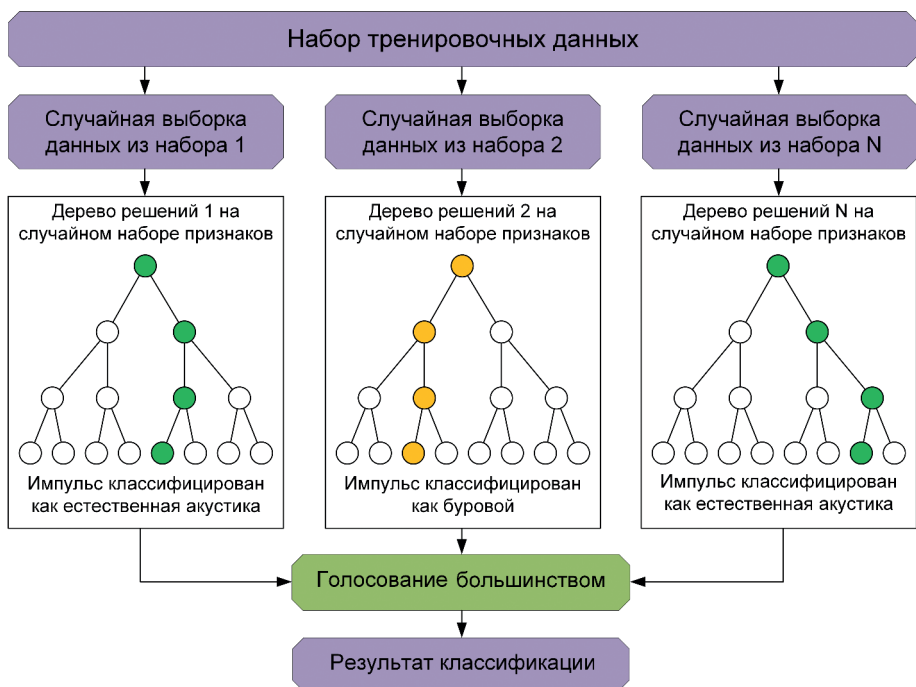


Рис. 7. Схема работы алгоритма случайного леса
 Fig. 7. The scheme of operation of the random forest algorithm

приводит к тому, что каждое дерево принимает решение на основе своей уникальной выборки, это снижает вероятность переобучения и увеличивает устойчивость модели. В случае классификации сигналов акустической эмиссии, каждое дерево предсказывает тип сигнала, а итоговое решение принимается на основе голосования деревьев. Схема работы алгоритма случайного леса представлена на рис. 7.

Размеченная база данных была разделена на две части. 70% составили данные для обучения модели случайного леса. Оставшиеся 30% для проверки корректности результата. Был проведен поиск оптимальной архитектуры модели случайного леса. Проведено 250 тренировок модели с кросс валидацией с помощью Байесовского метода и получены оптимальные гиперпараметры [17, 18].

Проверка точности модели

Для проверки точности обученной модели классификации в настоящее время используется подход, основанный на анализе матрицы ошибок классификации. В реальных классификационных моделях неизбежно возникают ошибки классификации, и их правильная интерпретация позволяет оценить фактическое качество модели [19]. Для этого используются следующие определения для каждого класса:

TP_N – (True Positives): число объектов, которые на самом деле относятся к классу N и предсказаны как N . Эти элементы всегда расположены на диагонали матрицы ошибок;

FP_N – (False Positives): число объектов, которые не относятся к классу N , но предсказаны как N ;

FN_N – (False Negatives): число объектов, которые на самом деле относятся

к классу N, но предсказаны как другой класс;

TN_N – (True Negatives): все остальное (объекты не относящиеся к N и не предсказанные как N).

Для каждого класса N обычно считаются следующие показатели:

Точность (Precision) показывает, насколько точны положительные предсказания модели

$$Precision_N = TP_N / (TP_N + FP_N). \quad (1)$$

Полнота (Recall) показывает, насколько хорошо модель находит все положительные примеры

$$Recall_N = TP_N / (TP_N + FN_N). \quad (2)$$

F1 показывает объединение обоих показателей, обеспечивая баланс между точностью и полнотой

$$F1_N = 2 \cdot (Precision_N \cdot Recall_N) / (Precision_N + Recall_N), \quad (3)$$

При необходимости вычисления общих показателей качества классификации вводится показатель Accuracy:

$$Accuracy = \frac{\sum_{i=1}^N TP_N}{K}, \quad (4)$$

где K – общее число объектов. Это самая простая метрика, показывающая, какой процент сигналов модель классифицировала правильно по всем классам. Однако если в выборке присутствует сильный дисбаланс (один из классов заметно чаще, чем другие), высокий показатель Accuracy еще не гарантирует хорошего качества модели.

Общий показатель F1 может вычисляться как

$$F1_{macro} = \frac{\sum_{i=1}^N F1_i}{N}, \quad (5)$$

в данном случае все классы равноправны, вне зависимости от числа экземпляров. Другой способ расчета общего F1 является взвешенным

$$F1_{weight} = \sum_{i=1}^N w_i F1_i, \quad (6)$$

Матрица ошибок

Фактический класс	Естественная АЭ	20,826	171	1,158
	Взрывные импульсы	19	4,512	27
	Бузовые импульсы	511	105	30,186
		Естественная АЭ	Взрывные импульсы	Бузовые импульсы
		Предсказанный класс		

Рис. 8. Матрица ошибок полученной модели

Fig. 8. Confusion matrix of the developed model

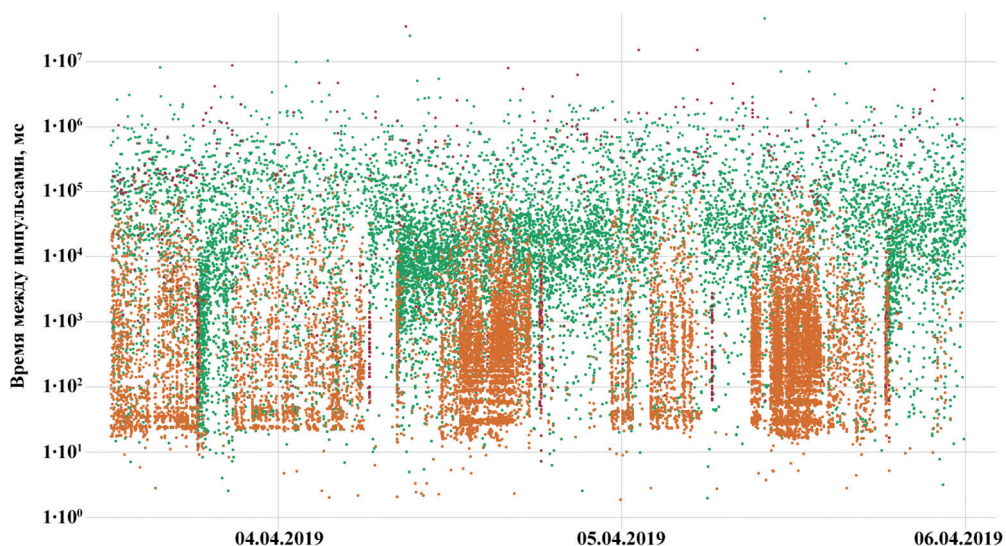


Рис. 9. Апробация полученной модели на участке базы неразмеченных данных
 Fig. 9. Testing the resulting model on a section of the unlabeled data base

Таблица 3

Параметры точности классификационной модели
Accuracy parameters of the classification model

	Точность	Полнота	F1
Естественная АЭ	0,9751	0,9400	0,9573
Взрывные импульсы	0,9423	0,9899	0,9655
Буровые импульсы	0,9622	0,9800	0,9710

На рис. 8 представлена матрица ошибок полученной модели, полученная на отложенной части сформированной выборки данных.

Рассчитанные параметры точности приведены в табл. 3.

В настоящее время проходит апробация специалистами возможностей модели перед ее внедрением в программное обеспечение анализа данных системы «Prognoz-ADS», а также рассматриваются возможности модернизации полученной модели с помощью применения нейросетевых классификаторов [20].

На рис. 9 представлена апробация полученной модели на участке базы неразмеченных данных Николаевского рудника за 2019 г.

Заключение

В исследовании представлены передовые методы и средства геомеханического мониторинга, основанные на технологиях машинного обучения и данных Николаевского рудника. Рассмотрены основные этапы проектирования классификационной модели машинного обучения. Создана обучающая выборка данных. Выполнена подготовка признакового пространства для классификации сигналов системы «Prognoz-ADS». Проведен тщательный отбор признаков с применением различных методик анализа. Составлен перечень признаков, включающий как базовые характеристики, рассчитываемые на стороне регистрирующего датчика, так и дополни-

тельные признаки, полученные в ходе анализа сигналов. Анализ распределения значений признаков и графики рассеяния подтвердили дифференциацию между категориями импульсов, что свидетельствует о корректности экспертной классификации импульсов в базе данных и является важным условием для работы моделей машинного обучения.

Примененный алгоритм машинного обучения (метод случайного леса) продемонстрировал высокую точность классификации, составившую более 95%. В настоящее время специалисты проводят апробацию модели перед ее внедрением в программное обеспечение анализа данных системы «Prognoz-ADS».

СПИСОК ЛИТЕРАТУРЫ

1. Козырев А. А., Батугин А. С., Жукова С. А. О влиянии обводненности массива на его сейсмическую активность при разработке апатитовых месторождений Хибин // Горный журнал. — 2021. — № 1. — С. 31–36. DOI: 10.17580/gzh.2021.01.06.
2. Рассказов И. Ю., Аникин П. А., Грунин А. П., Мигунов Д. С., Терешкин А. А. Совершенствование технических средств локального контроля удароопасности при ведении горных работ // Физико-технические проблемы разработки полезных ископаемых. — 2023. — № 5. — С. 177–184. DOI: 10.15372/FTPRPI20230519.
3. Abetov A., Kudaibergenova S., Sidorov V. Creation of geodynamic polygons and technologies for conducting geodynamic monitoring in the hydrocarbon fields // Engineering Journal of Satbayev University. 2021, vol. 143, no. 2, pp. 3–13. DOI: 10.51301/vest.su.2021.i2.01.
4. Рассказов И. Ю., Аникин П. А., Грунин А. П., Константинов А. В. Методы и средства геомеханического мониторинга для безопасного и эффективного освоения недр // Горный журнал. — 2025. — № 3. — С. 4–11. DOI: 10.17580/gzh.2025.03.01.
5. Рассказов И. Ю., Федотова Ю. В., Аникин П. А., Мигунов Д. С., Константинов А. В. Совершенствование методов и средств геомеханического мониторинга на основе цифровых технологий // Горная промышленность. — 2023. — № 55. — С. 18–24. DOI: 10.30686/1609-9192-2023-55-18-24.
6. Бычков И. В., Владимиров Д. Я., Опарин В. Н., Потапов В. П., Шокин Ю. И. Горная информатика и проблема «больших данных» в построении комплексных мониторинговых систем безопасности недропользования // Физико-технические проблемы разработки полезных ископаемых. — 2016. — № 6. — С. 163–179.
7. Song Y., Wang E., Yang H., Liu C., Di Y., Li B., Chen D. Comprehensive early warning of rockburst hazards based on unsupervised learning // Physics of Fluids. 2024, vol. 36, no. 7, article 076628. DOI: 10.1063/5.0221722.
8. Грунин А. П., Сидляр А. В., Косматов С. Б. Снижение погрешности локации сейсмоакустических событий в системе геомеханического мониторинга массива горных пород «Prognoz-ADS» // Вестник Тихоокеанского государственного университета. — 2024. — № 1(72). — С. 13–20.
9. Радисавлевич Й. Применение искусственных нейронных сетей для прогнозирования интенсивности сейсмических колебаний пород на медном руднике «Велики Кривель» // Физико-технические проблемы разработки полезных ископаемых. — 2023. — № 2. — С. 34–47. DOI: 10.15372/FTPRPI20230204.
10. Ahn H., Kim S., Lee K., Choi A., You K. Imbalanced seismic event discrimination using supervised machine learning // Sensors. 2022, vol. 22, article 2219. DOI: 10.3390/s22062219.
11. Zhang W. An improved DBSCAN algorithm for hazard recognition of obstacles in unmanned scenes // Soft Computing. 2023, vol. 27, pp. 18585–18604.
12. Schubert E., Sander J., Ester M., Kriegel H. P., Xu X. DBSCAN revisited, revisited: Why and how you should (still) use DBSCAN // ACM Transactions on Database Systems. 2017, vol. 42, no. 3, pp. 1–21. DOI: 10.1145/3068335.
13. Radeef Z. M., Hashem S. H., Gbashi E. K. New feature selection using principal component analysis // Journal of Soft Computing and Computer Applications. 2024, vol. 1, no. 2, article 1012. DOI: 10.70403/3008-1084.1012.

14. Das M. P., Dhar V. K., Verma S., Yadav K. K. Dimensionality reduction and sensitivity improvement for TACTIC Cherenkov data using t-SNE machine learning algorithm // *Nuclear Instruments and Methods in Physics Research Section A*. 2023, vol. 1057, article 168683. DOI: 10.1016/j.nima.2023.168683.
15. Jing R., Xue L., Li M., Yu L., Luo J. layerUMAP: A tool for visualizing and understanding deep learning models in biological sequence classification using UMAP // *iScience*. 2022, vol. 25, no. 12, article 105530. DOI: 10.1016/j.isci.2022.105530.
16. Butorin A., Mokhov G. Implementation of seismic facies analysis using the random forest classification // *ProGRESS'21, European Association of Geoscientists & Engineers*. 2021, vol. 2021, pp. 1 – 5. DOI: 10.3997/2214-4609.202159080.
17. Oktafiani R., Hermawan A., Avianto D. Max depth impact on heart disease classification: decision tree and random forest // *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*. 2024, vol. 8, pp. 160 – 168.
18. Doke P., Shrivastava D., Pan C., Zhou Q., Zhang Y.-D. Using CNN with Bayesian optimization to identify cerebral micro-bleeds // *Machine Vision and Applications*. 2020, vol. 31, article 67. DOI: 10.1007/s00138-020-01087-0.
19. Markoulidakis J., Kopsiaftis G., Rallis I., Georgoulas I. Multiclass confusion matrix reduction method and its application on net promoter score classification problem // *Technologies*. 2021, vol. 9, no. 4, article 81. DOI: 10.1145/3453892.3461323.
20. Mazumder P., Baruah S. A hybrid model for predicting classification dataset based on random forest, support vector machine and artificial neural network // *International Journal of Innovative Technology and Exploring Engineering*. 2023, vol. 13, pp. 19 – 25. DOI: 10.35940/ijtee.A9757.1213123. **PLAAS**

REFERENCES

1. Kozyrev A. A., Batugin A. S., Zhukova S. A. On the effect of water saturation of rock mass on its seismic activity during mining of Khibiny apatite deposits. *Gornyi Zhurnal*. 2021, no. 1, pp. 31 – 36. [In Russ]. DOI: 10.17580/gzh.2021.01.06.
2. Rasskazov I. Yu., Anikin P. A., Grunin A. P., Migunov D. S., Tereshkin A. A. Improvement of technical means for local control of rockburst hazard during mining operations. *Journal of Mining Sciences*. 2023, no. 5, pp. 177 – 184. [In Russ]. DOI: 10.15372/FTPRPI20230519.
3. Abetov A., Kudaibergenova S., Sidorov V. Creation of geodynamic polygons and technologies for conducting geodynamic monitoring in the hydrocarbon fields. *Engineering Journal of Satbayev University*. 2021, vol. 143, no. 2, pp. 3 – 13. DOI: 10.51301/vest.su.2021.i2.01.
4. Rasskazov I. Yu., Anikin P. A., Grunin A. P., Konstantinov A. V. Methods and means of geomechanical monitoring for safe and effective subsoil development. *Gornyi Zhurnal*. 2025, no. 3, pp. 4 – 11. [In Russ]. DOI: 10.17580/gzh.2025.03.01.
5. Rasskazov I. Yu., Fedotova Yu. V., Anikin P. A., Migunov D. S., Konstantinov A. V. Improvement of geomechanical monitoring methods and tools based on digital technologies. *Russian Mining Industry Journal*. 2023, no. S5, pp. 18 – 24. [In Russ]. DOI: 10.30686/1609-9192-2023-5S-18-24.
6. Bychkov I. V., Vladimirov D. Ya., Oparin V. N., Potapov V. P., Shokin Yu. I. Mining informatics and big data problem in creating integrated monitoring systems for mining safety. *Journal of Mining Sciences*. 2016, no. 6, pp. 163 – 179.
7. Song Y., Wang E., Yang H., Liu C., Di Y., Li B., Chen D. Comprehensive early warning of rockburst hazards based on unsupervised learning. *Physics of Fluids*. 2024, vol. 36, no. 7, article 076628. DOI: 10.1063/5.0221722.
8. Grunin A. P., Sidlyar A. V., Kosmatov S. B. Reducing the error of seismic-acoustic event location in the rock mass geomechanical monitoring system «Prognoz-ADS». *Bulletin of Pacific national university*. 2024, no. 1(72), pp. 13 – 20. [In Russ].
9. Radisavlevich J. Application of artificial neural networks for predicting seismic vibration intensity at Veliki Krivelj copper mine. *Journal of Mining Sciences*. 2023, no. 2, pp. 34 – 47. [In Russ]. DOI: 10.15372/FTPRPI20230204.
10. Ahn H., Kim S., Lee K., Choi A., You K. Imbalanced seismic event discrimination using supervised machine learning. *Sensors*. 2022, vol. 22, article 2219. DOI: 10.3390/s22062219.
11. Zhang W. An improved DBSCAN algorithm for hazard recognition of obstacles in unmanned scenes. *Soft Computing*. 2023, vol. 27, pp. 18585 – 18604.

12. Schubert E., Sander J., Ester M., Kriegel H. P., Xu X. DBSCAN revisited, revisited: Why and how you should (still) use DBSCAN. *ACM Transactions on Database Systems*. 2017, vol. 42, no. 3, pp. 1–21. DOI: 10.1145/3068335.
13. Radeef Z. M., Hashem S. H., Gbashi E. K. New feature selection using principal component analysis. *Journal of Soft Computing and Computer Applications*. 2024, vol. 1, no. 2, article 1012. DOI: 10.70403/3008-1084.1012.
14. Das M. P., Dhar V. K., Verma S., Yadav K. K. Dimensionality reduction and sensitivity improvement for TACTIC Cherenkov data using t-SNE machine learning algorithm. *Nuclear Instruments and Methods in Physics Research Section A*. 2023, vol. 1057, article 168683. DOI: 10.1016/j.nima.2023.168683.
15. Jing R., Xue L., Li M., Yu L., Luo J. layerUMAP: A tool for visualizing and understanding deep learning models in biological sequence classification using UMAP. *iScience*. 2022, vol. 25, no. 12, article 105530. DOI: 10.1016/j.isci.2022.105530.
16. Butorin A., Mokhov G. Implementation of seismic facies analysis using the random forest classification. *ProGREss'21, European Association of Geoscientists & Engineers*. 2021, vol. 2021, pp. 1–5. DOI: 10.3997/2214-4609.202159080.
17. Oktafiani R., Hermawan A., Avianto D. Max depth impact on heart disease classification: decision tree and random forest. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*. 2024, vol. 8, pp. 160–168.
18. Doke P., Shrivastava D., Pan C., Zhou Q., Zhang Y.-D. Using CNN with Bayesian optimization to identify cerebral micro-bleeds. *Machine Vision and Applications*. 2020, vol. 31, article 67. DOI: 10.1007/s00138-020-01087-0.
19. Markoulidakis J., Kopsiaftis G., Rallis I., Georgoulas I. Multiclass confusion matrix reduction method and its application on net promoter score classification problem. *Technologies*. 2021, vol. 9, no. 4, article 81. DOI: 10.1145/3453892.3461323.
20. Mazumder P., Baruah S. A hybrid model for predicting classification dataset based on random forest, support vector machine and artificial neural network. *International Journal of Innovative Technology and Exploring Engineering*. 2023, vol. 13, pp. 19–25. DOI: 10.35940/ijitee.A9757.1213123.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Грунин Алексей Петрович¹ — канд. техн. наук, старший научный сотрудник, e-mail: lexh188@mail.ru, ORCID ID: 0009-0002-2394-5608,
Константинов Александр Викторович¹ — научный сотрудник, e-mail: alex-sdt@yandex.ru, ORCID ID: 0000-0001-6481-292X,
Ломов Михаил Андреевич¹ — младший научный сотрудник, e-mail: 9241515400@mail.ru,
¹ Институт горного дела Дальневосточного отделения РАН.
Для контактов: Грунин А.П., e-mail: lexh188@mail.ru.

INFORMATION ABOUT THE AUTHORS

A.P. Grunin¹, Cand. Sci. (Eng.), Senior Researcher, e-mail: lexh188@mail.ru, ORCID ID: 0009-0002-2394-5608,
A.V. Konstantinov¹, Researcher, e-mail: alex-sdt@yandex.ru, ORCID ID: 0000-0001-6481-292X,
M.A. Lomov¹, Junior Researcher, e-mail 9241515400@mail.ru,
¹ Mining Institute of the Far Eastern Branch of Russian Academy of Sciences, 680000, Khabarovsk, Russia.
Corresponding author: A.P. Grunin, e-mail: lexh188@mail.ru.

Получена редакцией 30.07.2025; получена после рецензии 23.10.2025; принята к печати 17.11.2025.
Received by the editors 30.07.2025; received after the review 23.10.2025; accepted for printing 17.11.2025.