

ГОРНАЯ ИНФОРМАТИКА

УДК 622.23.05

ПРИМЕНЕНИЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ПРОГНОЗА ГЕОДИНАМИЧЕСКИХ ЯВЛЕНИЙ В МАССИВЕ ГОРНЫХ ПОРОД

А. И. Конури́н, Д. В. Орлов

*Институт горного дела им. Н. А. Чинакала СО РАН,
E-mail: konurin@misd.ru, Красный проспект, 54, 630091, г. Новосибирск, Россия*

Представлен перечень наиболее глубоких подземных сооружений различного назначения: шахт, рудников, туннелей, гидроэлектростанций и подземных исследовательских лабораторий. Показана возможная классификация горных ударов по механизму возникновения: перед выработанным пространством, в целике, вблизи тектонического нарушения. Выполнен анализ распространенных на практике систем прогноза удароопасности, выделены измерительные системы постоянного действия, данные которых подходят для машинной обработки. Приведена схема прогноза геодинамической обстановки на месторождении с использованием искусственных нейронных сетей. Выполнен сравнительный анализ методов машинного обучения для анализа геодинамических явлений. Показана структура искусственных нейронных сетей для прогнозирования геодинамических явлений и устойчивости горных выработок. Рассмотрены сейсмособытия на примере Шерегешского рудника. Установлена точность определения кластера сейсмособытия при использовании различных моделей. Наилучшие результаты показал метод k -средних (97.92 %).

Массив горных пород, горный удар, удароопасность, геодинамика, искусственные нейронные сети, машинное обучение

DOI: 10.15372/FTPRPI20250318

EDN: YZWPAC

Управление горным давлением играет ключевую роль в обеспечении безопасности и эффективности горных работ при разработке месторождений на больших глубинах. [1]. Современные технологии мониторинга, моделирования и прогноза напряженно-деформированного состояния массива способствуют безопасной разработке удароопасных месторождений [2–4].

АКТУАЛЬНОСТЬ ИССЛЕДОВАНИЯ

Проблема проявления горного давления в динамической форме актуальна не только для горнодобывающих предприятий России [5–7], но и для предприятий Австралии [8], Канады [9, 10], Китая [11–13], Южной Африки [14] и других стран. В горнодобывающих отраслях промышленности в связи с быстрым ростом глубины горных работ на подземных рудниках, а также увеличе-

нием напряжений в массиве горных пород обостряется проблема управления горным давлением. На достигнутых глубинах на целом ряде рудников и шахт, особенно в тектонически и сейсмически активных районах, возникают катастрофические явления, связанные с проявлениями горного давления в обрабатываемых массивах месторождений в форме техногенных землетрясений, ударов горно-тектонического типа, внезапных выбросов угля и газа, породы и газа, обрушения больших масс горных пород, прорывов воды и др. [15].

В мировой практике строительства и эксплуатации технологических объектов накоплен большой объем экспериментальных данных. Состояние массива горных пород на больших глубинах изучается не только при добыче полезных ископаемых, но и при строительстве объектов различного назначения: туннелей, гидроэлектростанций (HPS) и подземных исследовательских лабораторий (URLs) (табл. 1). Накопленный опыт прогноза удароопасности на этих предприятиях показывает, что такие объемы данных эффективно обработать можно только методами машинного обучения.

ТАБЛИЦА 1. Наиболее глубокие подземные сооружения [16]

Глубина, м	Наименование	Страна	Глубина, м	Наименование	Страна
4000	Mponeng Gold Mine	ЮАР	1838	Pribram Uranium Mines	Чехия
3900	TauTona Gold Mine	ЮАР	1800	SDAG Wismut Uranium Mine (закрыта)	Германия
3700	Savuka Gold Mine	ЮАР	1720	Headrace Tunnel of Qireha Starr HPS	Китай
3400	Driefontein Gold Mine	ЮАР	1700	Modane URLs	Франция
3276	Kusasaletu Gold Mine	ЮАР	1678	Headrace Tunnels at Jiangbian HPS	Китай
3200	Kolar Gold Mine	Индия	1650	Guaneiba Tunnel for Chenkun Railway	Китай
3054	Moab Khotsong Gold Mine	ЮАР	1600	Baksan URLs	Россия
3008	LaRonde Gold – Copper – Silver Mine	Канада	1600	Qinling Zhongnanshan Extra Long Highway Tunnel	Китай
2995	South Deep Gold Mine	ЮАР	1550	Шахта Черемуховская – Глубокая	Россия
2927	Kidd Creek Copper Zinc Mine	Канада	1500	Рудник Таймырский	Россия
2920	Lucky Friday Silver Lead Zinc	США	1400	Gran Sasso URLs	Италия
2600	Great Noligwa Gold Mine	ЮАР	1347	Sangzhuling Tunnel	Китай
2500	Creighton Nickel Mine	Канада	1315	Diversions Tunnel of a HPS	Непал
2500	Lyon – Turin base Tunnel	Италия	1300	Boulby (potash) mine	Великобритания
2400	Jinping URLs	Китай	1300	India – based neutrino observatory (INO)	Индия
2300	Dusel URLs	США	1275	Angen – Pop Railway Tunnel	Узбекистан
2200	Merensky Reef Platinum Mine	ЮАР	1270	The Yacambu – Qulbor Tunnel	Венесуэла
2080	Bayu Tunnel in Sichuan – Tibet Railway	Китай	1200	The Guigala Expressway Tunnel	Китай
2056	Рудник Скалистый	Россия	1100	Шахта Комсомольская	Россия
2000	SNO URLs	Канада	1100	Boulby URLs	Великобритания
1900	Mount Isa Copper Mine	Австрия	1050	Chongqing Tongyu Tunnels	Китай
1900	Headrace Tunnel of Neelum-Jhelum HPS	Пакистан	1000	The Kuhrang Tunnel Project	Иран

МЕХАНИЗМЫ ВОЗНИКНОВЕНИЯ ГОРНЫХ УДАРОВ И МЕТОДЫ ИХ ОЦЕНКИ

На протяжении многих лет прогноз геодинамических явлений основывается на анализе шелушения, стрельяния, предварительных толчков и других изолированных сейсмических событий. В современных исследованиях используется информация, которую можно собрать во время относительно спокойных периодов между крупными геодинамическими явлениями. При проходке горных выработок горный удар может быть обусловлен тремя типичными механизмами (рис. 1) [17]:

а) напряжения, определяющие возникновение горного удара, концентрируются перед забоем выработки, область между этой напряженной зоной и забоем становится нестабильной, что приводит к внезапному разрушению и выбросу горной породы в выработку;

б) при горном ударе в целике напряжения концентрируются в ядре целика, что приводит к перенапряжению, внезапному разрушению и выбросу горной породы в окружающие камеры;

в) при горном ударе вблизи тектонического нарушения рост действующих напряжений в точке происходит за счет суперпозиции касательных (τ) и нормальных напряжений (σ_N).

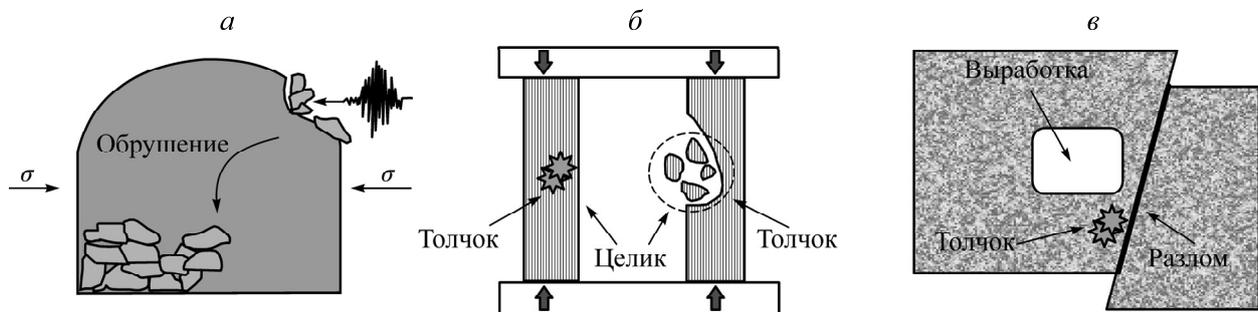


Рис. 1. Типовые механизмы возникновения горного удара: а — перед выработанным пространством; б — в целике; в — вблизи тектонического нарушения

Горный удар, обусловленный третьим механизмом возникновения, — наиболее сложен как для прогнозирования, так и для предотвращения, поскольку ни точная конфигурация разлома, ни физико-механические свойства слагающих его пород по очевидным причинам достоверно неизвестны. Горный удар со вторым механизмом возникновения достаточно просто предотвратить за счет выбора технологии горных работ: извлечение запасов без образования (с минимальным количеством) межшахтных целиков, острых углов и выступов, а также ограничение встречных и догоняющих фронтов очистных работ [18]. Первый вариант возникновения горного удара — наиболее прогнозируемый, поскольку рост напряжений в этом случае будет сопровождаться внешними проявлениями, которые можно инструментально зафиксировать. При этом с высокой вероятностью могут быть приняты своевременные меры по его предотвращению, сохранению горной выработки и оборудования.

Базовым методом прогноза удароопасности массива на глубинных рудниках остается метод дискования керна геологоразведочных скважин [19, 20]. Анализ данных кернового бурения на Таштагольском месторождении [21] демонстрирует четкую корреляцию между зоной максимального опорного давления и интенсивным разрушением керна (рис. 2). Данное явление объясняется значительным ростом напряжений в этом участке, вызванным изменением естественного напряженного состояния массива в процессе ведения горных работ.

Поскольку оперативный анализ удароопасности методом дискования керна невозможен (керновые скважины бурятся дискретно и в небольшом количестве), высокие перспективы имеет оценка мониторинговых данных, собранных в процессе бурения [22] или сразу после него, при проведении эндоскопических исследований [23].

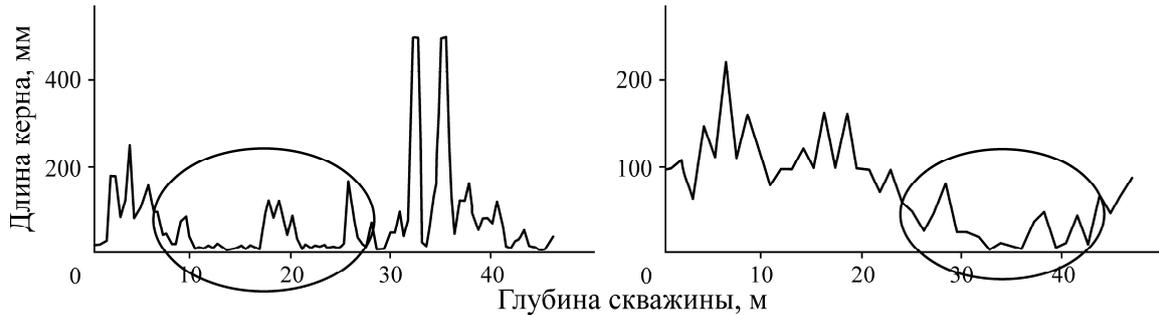


Рис. 2. Распределение длины кернов по скважинам в зависимости от глубины

В той же области массива, где наблюдается дискование керна, как правило, фиксируется повышенное количество сейсмособытий. Анализ распределения геодинамических явлений при отработке блоков на Таштагольском месторождении показал, что сейсмические события локализуются в области расположения максимума зоны опорного давления. Проекция распределения сейсмособытий по простиранию месторождения приведены на рис. 3. Контуром отмечена граница выработанного пространства. События разделены по энергетическому классу (десятичный логарифм энергии события).

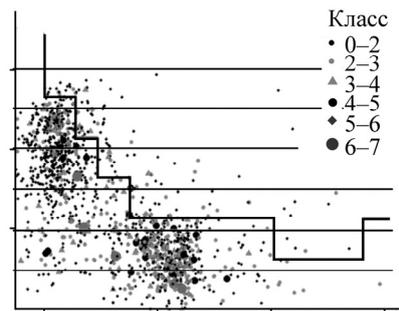


Рис. 3. Распределение сейсмособытий в проекции по простиранию Таштагольского месторождения.

На практике при организации геомеханического мониторинга на горных предприятиях для обеспечения безопасности горных работ широко применяется контроль деформаций вмещающего массива. Для наблюдений за деформациями массива пород чаще используются методы глубинных и контурных реперов, метод инклинометрии, измерение конвергенции подземных выработок с помощью ленточных экстензометров. Многореперные скважинные системы, основанные на механическом принципе измерений [24], представляют собой практическую реализацию метода глубинных реперов. Конструктивно система состоит из линейно расположенных в стволе скважины (шпура) реперных маркеров, включая контрольную точку в устье. Регистрируя взаимное смещение реперов при деформациях кровли, устройство обеспечивает мониторинг устойчивости массива и диагностику предразрушающих состояний. Минимальная конфигурация системы содержит пару реперов, относительное перемещение которых количественно характеризует развитие расслоений. Перечисленные методы позволяют создать мониторинговую систему, работающую непрерывно, что важно для машинной обработки.

К наиболее оптимальным для построения измерительных систем постоянного действия относятся локационные методы определения конвергенции, основанные на зондирующих сигналах различной природы: сверхвысокочастотные электромагнитные, оптические или ультразвуковые локационные системы. Достоинства и недостатки локационных методов определения конвергенции показаны на рис. 4.



Рис. 4. Локационные методы определения конвергенции горных выработок

В настоящее время для реализации геотехнического мониторинга на предприятиях используется широкий диапазон измерительных датчиков с разными параметрами: разрешающей способностью, погрешностью измерений, используемым протоколом обмена информацией и т. д. Многообразие систем мониторинга на предприятиях часто приводит к тому, что результаты прогноза, полученные различными способами, противоречат друг другу. Ручная обработка таких объемов данных — весьма трудоемкий процесс. Наиболее эффективным методом анализа подобных больших объемов разнородных данных является машинное обучение [25].

МЕТОДЫ РЕГРЕССИОННОГО АНАЛИЗА В МАШИННОМ ОБУЧЕНИИ

Выбор оптимального алгоритма машинного обучения для анализа и прогнозирования геодинамических явлений представляет собой сложную задачу. Регрессионный анализ позволяет количественно оценить взаимосвязь между параметрами горного массива (напряжения, деформации, физико-механические свойства) и геодинамическими явлениями, что дает возможность прогнозировать их возникновение. С помощью методов множественной регрессии устанавливаются статистически значимые зависимости между факторами воздействия (глубина разработки, мощность пласта, темп подвигания забоя) и откликом массива (смещения, сейсмическая активность). Нелинейные регрессионные модели, учитывающие пороговые эффекты, особенно эффективны для прогнозирования критических состояний массива, предшествующих горным ударам.

Линейная регрессия (ЛР) представляет собой базовый метод регрессионного анализа, устанавливающий линейную зависимость между входными параметрами (напряженное состояние, физико-механические свойства пород) и выходной переменной (деформации, сейсмическая активность). Как базовый алгоритм машинного обучения, ЛР демонстрирует высокую интерпретируемость результатов и простоту реализации, что делает этот метод эффективным инстру-

ментом для первичного анализа геодинамических процессов. Однако ограниченность линейной аппроксимации требует дополнения более сложными методами для учета нелинейных эффектов, характерных для горных массивов.

Адаптация нейронных сетей для решения регрессионных задач в геодинамике достигается модификацией выходного слоя — заменой классических активационных функций (сигмоида, ReLU) на линейное преобразование. Такие модели сохраняют способность выявлять сложные нелинейные зависимости между параметрами массива, одновременно обеспечивая прогнозирование непрерывных значений (величин смещений, уровней напряжений). Это особенно ценно при анализе пространственно-временной динамики геодинамических процессов.

Регрессионные деревья прогнозируют непрерывные значения параметров массива через систему бинарных решений. Критическое значение имеет оптимизация глубины дерева: чрезмерное усложнение модели приводит к переобучению на шумах мониторинговых данных, недостаточная глубина снижает прогностическую способность. Метод эффективен для анализа локальных геодинамических процессов с четко выраженными пороговыми эффектами, поскольку пороговый характер разбиений деревьев хорошо соответствует резким переходам состояний массива.

LASSO-регрессия (L1-регуляризация) автоматически исключает малозначимые параметры, что критически важно при работе с многомерными геомеханическими данными, где многие показатели коррелированы. Метод обеспечивает отбор наиболее информативных признаков для прогноза динамических явлений.

Ридж-регрессия (L2-регуляризация) предпочтительна при анализе систем, где множество малозначимых факторов в совокупности определяют геодинамическое состояние. Метод минимизирует проблему мультиколлинеарности без исключения переменных.

Представленные методы образуют иерархию подходов к анализу геодинамических процессов — от простых линейных моделей до сложных регуляризованных алгоритмов. Выбор конкретного метода должен определяться характером решаемой задачи: линейная регрессия подходит для первичного анализа, нейросетевые модели для учета сложных нелинейностей, регуляризованные методы для работы с многомерными коррелированными данными мониторинга. Комбинация этих подходов позволяет создавать эффективные системы прогнозирования опасных геодинамических явлений. Валидация моделей на основе данных мониторинга дает возможность уточнить прогнозные оценки и адаптировать их к конкретным горно-геологическим условиям.

СТРУКТУРА ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ ДЛЯ АНАЛИЗА ГЕОДИНАМИЧЕСКИХ ЯВЛЕНИЙ

Искусственные нейронные сети (ИНС, Artificial neural network, ANN) — один из известных методов машинного обучения, который разработан на основе математической модели активности нервной системы в человеческом мозге. Современные модели ИНС способны предсказывать и решать задачи с высокой точностью. В настоящее время происходит активное внедрение различных моделей ИНС в промышленность [26]. Теоретически ИНС состоит из трех частей: входного слоя, одного или нескольких скрытых слоев и выходного слоя (рис. 6). В каждом слое содержатся нейроны, которые выполняют различные задачи. Во входном слое проводится сбор и передача входных данных в скрытые слои. В скрытых слоях передаются данные от входных нейронов через закодированные значения, называемые весами [27]. Процедура расчета и обработки выполняется в скрытых слоях посредством различных методов обучения и алгоритмов, которые подбираются для конкретной задачи. После этого результаты передаются из скрытых слоев в выходной слой.

На рис. 5 представлена структура ИНС для прогнозирования геодинамических явлений и устойчивости горных выработок в соответствии с данными мониторинга.

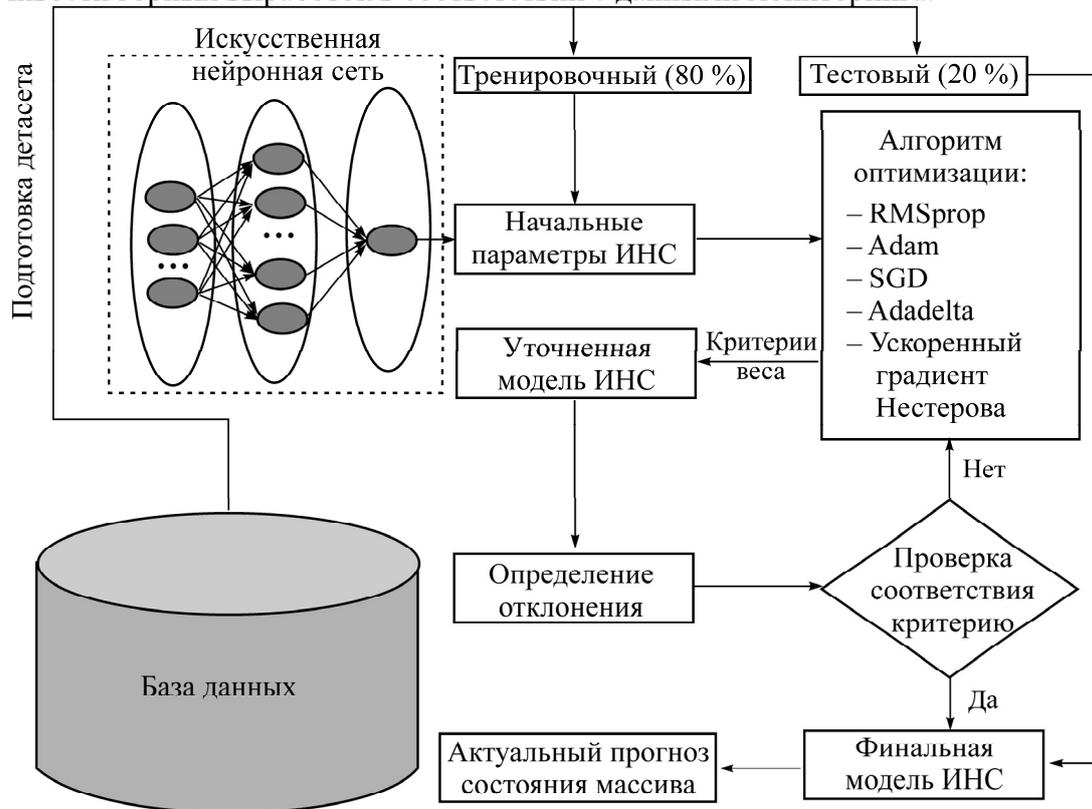


Рис. 5. Процесс обучения ИНС для прогнозирования геодинамических явлений и устойчивости горных выработок

На первом этапе происходит подготовка датасета (набора данных) на основе исторических данных. Датасет разделяется на обучающие и тестовые наборы данных. На следующих этапах проводится первичное обучение ИНС с инициализацией весов и смещений слоев. Затем применяется алгоритм для оптимизации весов между нейронами и смещений каждого слоя. Процесс повторяется до достижения наилучшей точности прогноза.

КЛАСТЕРНЫЙ АНАЛИЗ СЕЙСМОСОБЫТИЙ НА ШЕРЕГЕШСКОМ РУДНИКЕ

На основе данных сейсмостанции Шерегешского рудника за 2024 г. разработан методологический подход для прогнозирования пространственного распределения геодинамических событий.

Исторические данные о геодинамических событиях подвергаются трехмерной кластеризации с учетом координат (x, y, z) их возникновения. Кластерный анализ позволяет выявить зоны концентрации событий в горном массиве. С использованием данного подхода можно перейти от точечного анализа отдельных событий к комплексной оценке геодинамического состояния массива, что в комбинации с другими методами способствует повышению точности прогнозов [28]. Особое значение имеет корректное определение числа кластеров, так как это непосредственно влияет на достоверность последующего анализа.

Ключевыми параметрами, значения которых наиболее значимы в качестве входных данных для алгоритма регрессии, являются координаты в пространстве (X, Y, Z), энергия, степень и длительность события, а также дата и время начала события. Остальные параметры — производные или имеют меньшую значимость для алгоритма (участок, привязка, горизонт), поэтому на начальном этапе в работе не используются.

На рис. 6 приведены тепловые карты сейсмособытий. Они имеют типовой вид и отражают концентрацию сейсмособытий в определенных областях месторождения. Чаще всего точки сконцентрированы в одной из областей определенного горизонта. Реже концентрации точек встречаются в пространствах между горизонтами.

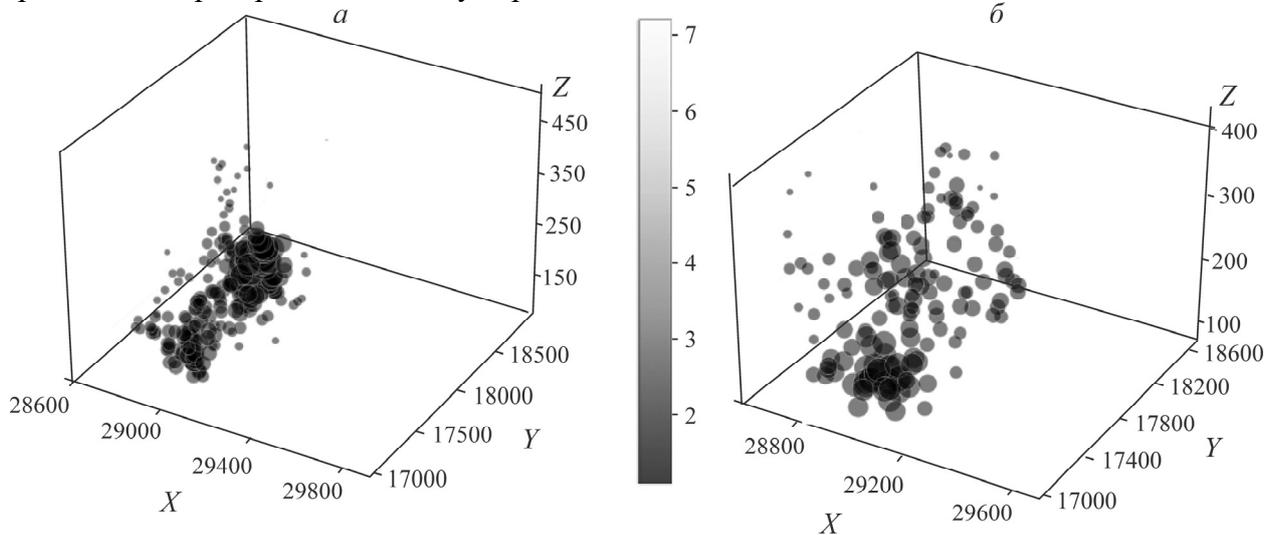


Рис. 6. Тепловые карты сейсмособытий в Шерегешском руднике: *a* — март; *б* — октябрь 2024 г.

Вычисление областей концентрации точек выполнено распространенным методом кластеризации — методом k -средних [29]. Действие алгоритма заключается в стремлении минимизировать суммарное квадратичное отклонение точек кластеров от их центров:

$$V = \sum_{i=1}^k \sum_{x \in S_i} (x - \mu_i)^2,$$

где k — число кластеров; S_i — полученные кластеры, $i = 1, 2, \dots, k$, а μ_i — центры масс всех векторов x из кластера S_i .

Определение числа кластеров осуществляется методом плеча для k -средних, чтобы вычислить оптимальное значение k . Для анализируемых данных оптимальным количеством кластеров является 5, что обусловлено анализом совокупности полученных конфигураций кластеров с учетом среднего расстояния от точки до центра кластера, времени кластеризации и экспертной оценки полученных событий. Расчет оптимального значения k выполняется пересечением графиков среднего расстояния от точки до центра кластера и времени определения кластера, к которому относится новое значение (рис. 7).

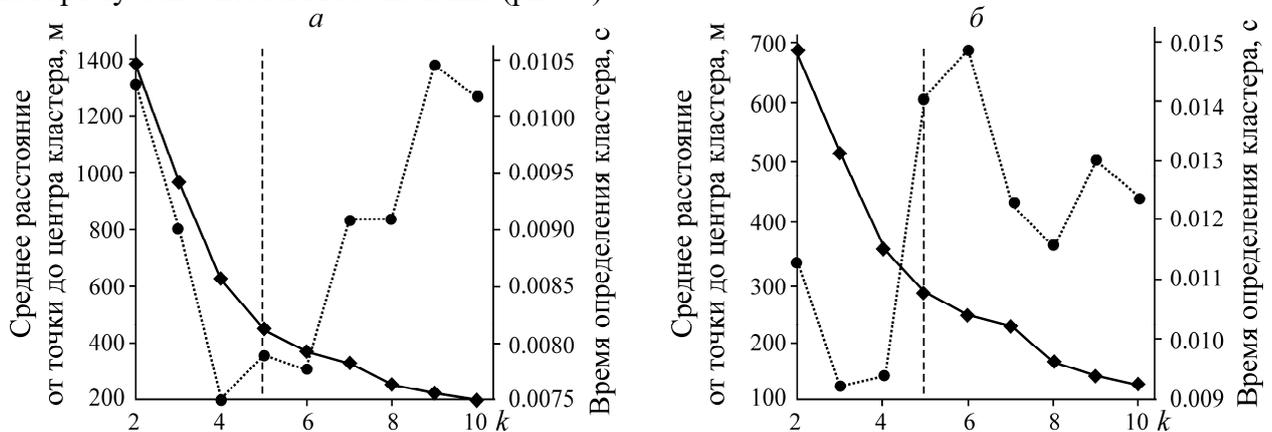


Рис. 7. Распределение кластеров по методу плеча для k -средних: *a* — март; *б* — октябрь 2024 г.

Разбиение сейсмособытий на кластеры с использованием метода k -средних со значением показано на рис. 8 (кластеры обозначены разными маркерами).

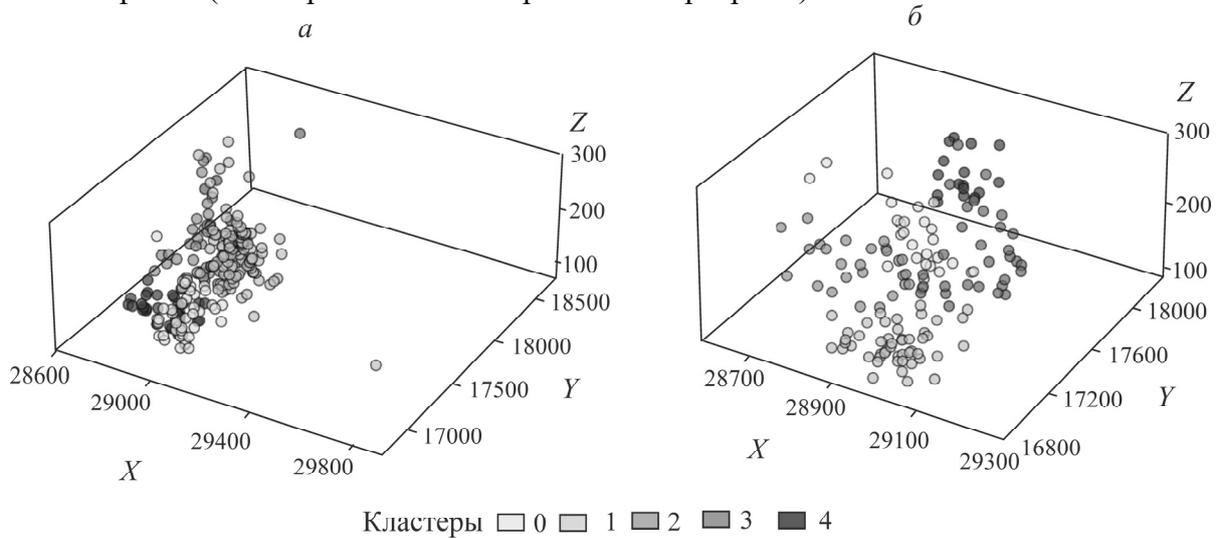


Рис. 8. Разбиение сейсмособытий на кластеры с использованием метода k -средних: *а* — март; *б* — октябрь 2024 г.

Данные с метками кластеров разделены в соотношении 80 : 20 между тренировочной и тестовой выборками. Обучение происходило с использованием 10 различных моделей разбиения точек на кластеры в пространстве признаков. Для разбиения использовались 5 параметров: положение в пространстве (координаты X , Y , Z), энергия и длительность сейсмособытия. Для дальнейшей работы параметры сокращались до трех с помощью метода анализа главных компонент (Principal component analysis — PCA). Этот метод позволил снизить размерность пространства признаков до трехмерного. После этого проводилась нормализация значений компонент и разбиение на кластеры. На рис. 9 приведено сравнение всех испытанных моделей для определения кластера на тестовой выборке данных.

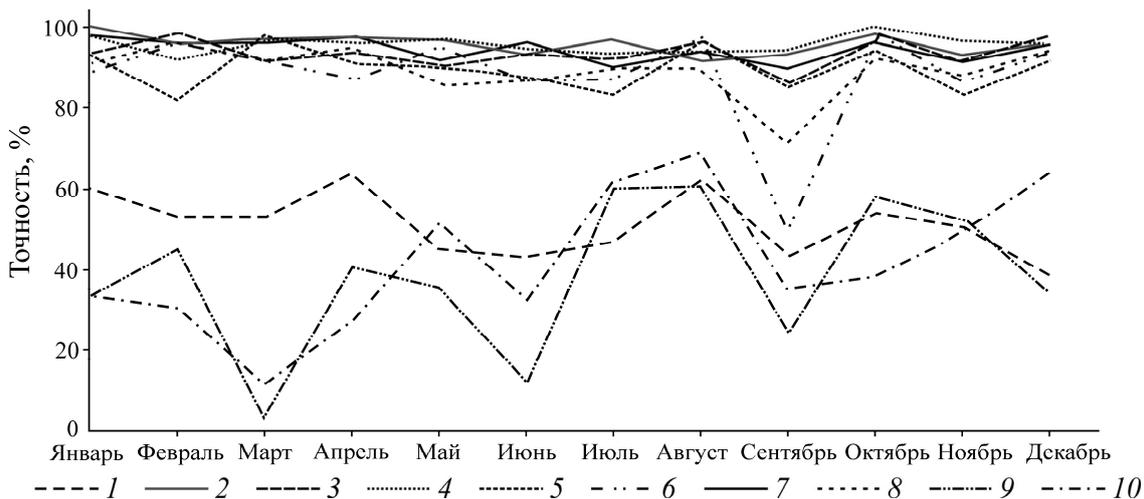


Рис. 9. Точность методов при кластеризации сейсмических событий: 1 — метод опорных векторов; 2 — метод случайного леса; 3 — линейный метод опорных векторов; 4 — градиентный бустинг; 5 — метод K -ближайших соседей; 6 — наивный байесовский классификатор; 7 — дерево решений; 8 — логистическая регрессия; 9 — перцептрон; 10 — стохастический градиентный спуск

В результате определены наиболее подходящие модели для кластерного анализа концентрации сейсмических событий: метод случайного леса (средняя точность — 95.76%), градиентный бустинг (95.67%), дерево решений (94.31%), линейный метод опорных векторов (93.25%), метод К-ближайших соседей (89.56%). Полученные кластерные характеристики служат основой для оценки геодинамической опасности, прогноза пространственного распределения будущих событий, определения зон повышенного риска.

ВЫВОДЫ

Прогнозирование геодинамической обстановки на месторождениях с применением искусственных нейронных сетей обеспечивает моделирование и учет нелинейных взаимосвязей между геомеханическими параметрами. Сравнительный анализ эффективности методов машинного обучения в контексте геодинамических процессов позволил идентифицировать оптимальные алгоритмы для решения специализированных задач, включая прогнозирование устойчивости горных выработок. Детально описана архитектура ИНС, адаптированная для прогнозирования геодинамических явлений, с акцентом на ее способность к обработке многомерных данных. Оценка пространственно-временных закономерностей сейсмических событий на примере Шерегешского рудника позволила определить наиболее релевантные модели для кластеризации их концентрации. Максимальную точность продемонстрировали: метод случайного леса (95.76%), градиентный бустинг (95.67%), дерево решений (94.31%), линейный метод опорных векторов (93.25%) и метод К-ближайших соседей (89.56%). Полученные кластерные характеристики могут быть положены в основу методики оценки геодинамических рисков, включая прогноз пространственного распределения потенциальных событий, идентификацию зон повышенной опасности и оптимизацию мероприятий по обеспечению безопасности горных работ. Результаты исследования подтверждают перспективность интеграции нейросетевых технологий и методов машинного обучения в системы геодинамического мониторинга.

СПИСОК ЛИТЕРАТУРЫ

1. Адушкин В. В., Беседина А. Н., Кочарян Г. Г., Семенова И. Э., Жукова С. А., Журавлева О. Г. Новый подход к контролю опасности техногенных землетрясений в окрестности горнодобывающих предприятий // Докл. РАН. Науки о Земле. — 2024. — Т. 519. — № 1. — С. 527–534.
2. Курленя М. В., Сердюков А. С., Азаров А. В., Никитин А. А. Численное моделирование волновых полей от микросейсмических событий при подземной добыче полезных ископаемых // ФТПРПИ. — 2015. — № 4. — С. 61–69.
3. Штирц В. А., Еременко А. А., Конуринов А. И., Клишин И. В. Опыт прогноза геодинамических явлений при массовых взрывах // ГИАБ. — 2015. — № 7. — С. 196–206.
4. Бизяев А. А., Вострецов А. Г., Смирнягин И. И., Шарапова М. Д. Оценка напряженно-деформированного состояния массива горных пород по его электромагнитному излучению // ФТПРПИ. — 2024. — № 6. — С. 192–199.
5. 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 // ФТПРПИ. — 2023. — № 5. — С. 177–184.
6. Еременко В. А., Хажылылай Ч. В., Умаров А. Р., Лагутин Д. В. Количественная оценка напряженно-деформированного состояния горного массива Северомуйского тоннеля // Горн. журн. — 2023. — № 1. — С. 58–64.

7. **Простов С. М., Разумов Е. Е., Мулев С. Н., Шабанов Е. А.** Расчетная и аппаратная база геомониторинга состояния массива методом регистрации естественного электромагнитного излучения // Изв. ТПУ. Инжиниринг георесурсов. — 2022. — Т. 333. — № 11. — С. 183–193.
8. **Hu X., Su G., Li Z., Xu C., Yan X., Liu Y., and Yan L.** Suppressing rockburst by increasing the tensile strength of rock surface: An experimental study, *Tunnelling and Underground Space Technol.*, 2021, Vol. 107. — 103645.
9. **Pu Y., Apel D. B., and Xu H.** Rockburst prediction in kimberlite with unsupervised learning method and support vector classifier, *Tunnelling and Underground Space Technol.*, 2019, Vol. 90. — P. 12–18.
10. **Manouchehrian A. and Cai M.** Numerical modeling of rockburst near fault zones in deep tunnels, *Tunnelling and Underground Space Technol.*, 2018, Vol. 80. — P. 164–180.
11. **Wang S., Huang L., and Li X.** Analysis of rockburst triggered by hard rock fragmentation using a conical pick under high uniaxial stress, *Tunnelling and Underground Space Technol.*, 2020, Vol. 96. — 103195.
12. **Liu F., Ma T., Tang C., and Chen F.** Prediction of rockburst in tunnels at the Jinping II hydropower station using microseismic monitoring technique, *Tunnelling and Underground Space Technol.*, 2018, Vol. 81. — P. 480–493.
13. **Xue Y., Bai C., Qiu D., Kong F., and Li Z.** Predicting rockburst with database using particle swarm optimization and extreme learning machine, *Tunnelling and Underground Space Technol.*, 2020, Vol. 98. — 103287.
14. **Mogamedi K. A. and Stacey T. R.** Value creation as an approach to the management and control of rockburst damage in tunnels, *Tunnelling and Underground Space Technol.*, 2018, Vol. 83. — 545–551.
15. **Зубков А. А.** Интенсификация горных работ и снижение рисков эксплуатации рудного месторождения системами разработки с твердеющей закладкой при переходе к новому технологическому укладу: автореф. дисс. ... д-ра техн. наук. — Магнитогорск, 2022. — 360 с.
16. **Zhou J., Zhang Y., Li C., He H., and Li X.** Rockburst prediction and prevention in underground space excavation, *Underground Space*, 2024, Vol. 14. — P. 70–98.
17. **Oliver L.C., Sampara P., Pearson D., Martell J., and Zarnke A. M.** Sarcoidosis in Northern Ontario hard-rock miners: A case series, *Am. J. Ind. Med.*, 2022, Vol. 65, No. 4. — P. 268–280.
18. **Козырев А. А., Кузнецов Н. Н., Макаров А. Б.** О критериях удароопасности горных пород // Горн. пром-сть. — 2023. — № S1. — С. 61–68.
19. **Раимжанов Б. Р., Хасанов А. Р., Фарманов О. Э.** Исследование геодинамического состояния массива горных пород с целью прогнозирования горных ударов // ГИАБ. — 2021. — № 10. — С. 29–41.
20. **Сидоров Д. В., Потапчук М. И., Сидляр А. В.** Прогнозирование удароопасности тектонически нарушенного рудного массива на глубоких горизонтах николаевского полиметаллического месторождения // Зап. Горн. института. — 2018. — Т. 234. — С. 604–611.
21. **Ерёменко А. А., Конури́н А. И., Штирц В. А., Приб В. В.** Выявление зон повышенного горного давления на удароопасном железорудном месторождении // Горн. журн. — 2020. — № 1. — С. 78–81.
22. **Orarin V. N., Karpov V. N., Timonin V. V., and Konurin A. I.** Evaluation of the energy efficiency of rotary percussive drilling using dimensionless energy index, *J. Rock Mech. and Geotech. Eng.*, 2022, No. 14. — P. 1486–1500.
23. **Орлов Д. В., Конури́н А. И., Кудря А. О., Неверов С. А.** Идентификация структуры горных пород на основе сегментации цифровых изображений // Фундаментальные и прикладные вопросы горных наук. — 2022. — Т. 9. — № 3. — С. 128–135.
24. **Барышников В. Д., Барышников Д. В.** Контроль сдвижений и деформаций породного массива в окрестности горных выработок // Изв. ТулГУ. Науки о Земле. — 2023. — № 3. — С. 394–403.

25. **Ma T. H., Tang C. A., Tang S. B., Kuang L., Yu Q., Kong D.-Q., and Zhu X.** Rockburst mechanism and prediction based on microseismic monitoring, *Int. J. Rock Mech. Min. Sci.*, 2018, Vol. 110. — P. 177–188.
26. **Zhang X., Nguyen H., Bui X. N., Le H. A., Nguyen-Thoi T., Moayedi H., and Mahesh V.** Evaluating and predicting the stability of roadways in tunnelling and underground space using artificial neural network-based particle swarm optimization, *Tunnelling and Underground Space Technol.*, 2020, Vol. 103. — 103517.
27. **Bui X. N., Nguyen H., Choi Y., Nguyen-Thoi T., Zhou J., and Dou J.** Prediction of slope failure in open-pit mines using a novel hybrid artificial intelligence model based on decision tree and evolution algorithm, *Scientific Reports*, 2020, Vol. 10. — 9939.
28. **Zhang H., Xia Y., Lin M., Huang J., and Yan Y.** A three-step rockburst prediction model based on data preprocessing combined with clustering and classification algorithms, *Bull. Eng. Geology Env.*, 2024, Vol. 83 — 266.
29. **Токарев Д. М., Городничев М. Г.** Обнаружение аномалий на основе машинного обучения с использованием сочетания алгоритмов k -mean и smo // Телекоммуникации и информационные технологии. — 2023. — Т. 10. — № 1. — С. 5–13.

Поступила в редакцию 24/III 2025

После доработки 12/V 2025

Принята к публикации 16/V 2025