

Автоматизация классификации сейсмических событий при сейсмомониторинге угольной шахты с использованием машинного обучения

К.В. Романевич✉, С.Н. Мулёв

Научно-исследовательский институт горной геомеханики и маркшейдерского дела – межотраслевой научный центр «ВНИМИ», г. Санкт-Петербург, Российская Федерация

✉ romanevichkirill@gmail.com

Резюме: Исследование посвящено разработке алгоритма автоматической классификации сейсмических событий в контексте мониторинга сейсмоактивности на угольных шахтах и рудниках с использованием методов машинного обучения. Отмечается важность классификации геодинамических процессов и явлений в аспекте понимания природы сейсмических явлений, выявления их источников, оценки потенциальной опасности и воздействия на окружающую среду и инфраструктуру подземных сооружений. В статье описан алгоритм анализа сейсмической активности на основе данных, полученных в результате регистрации сейсмических событий с использованием аппаратного комплекса и программного обеспечения сейсмомониторинга GITS2 на угольной шахте. В работе кратко рассмотрены ключевые методы искусственного интеллекта, применяемые для контроля и прогнозирования опасных геодинамических явлений. Особое внимание уделено разработке модели машинного обучения, основанной на решающих деревьях, которая демонстрирует высокую точность при классификации сейсмических событий.

Точность классификации разработанной модели на обучающей выборке составила 98,39%, а на тестовой выборке – 98,41%. Этот результат свидетельствует о высокой обобщающей способности модели на новых данных и отсутствии переобучения. Проверка алгоритма на новых данных, поступающих в систему сейсмомониторинга GITS2, также подтверждает высокую точность классификации типов сейсмических событий на уровне 83–93%. Это подчеркивает эффективность машинного обучения в контексте контроля сейсмического режима шахты. Разработанная модель машинного обучения после ее опытной эксплуатации будет внедрена в мониторинговую систему GITS2, что позволит производить классификацию поступающих сейсмических событий в автоматическом режиме.

Ключевые слова: шахта, сейсмические события, сейсмомониторинг, методы искусственного интеллекта, машинное обучение, алгоритм классификации, решающие деревья, Catboost

Для цитирования: Романевич К.В., Мулёв С.Н. Автоматизация классификации сейсмических событий при сейсмомониторинге угольной шахты с использованием машинного обучения. *Горная промышленность*. 2023;(5S):58–64. <https://doi.org/10.30686/1609-9192-2023-5S-58-64>

Automation of seismic events classification during seismic monitoring at a coal mine using machine learning

K.V. Romanevich✉, S.N. Mulev

Research Institute of Mining Geomechanics and Mine Surveying – Interdisciplinary Research Center “VNIMI”, St. Petersburg, Russian Federation

✉ romanevichkirill@gmail.com

Abstract: The paper is dedicated to the development of an algorithm for automatic classification of geodynamic processes in the context of monitoring seismic activity in mines using machine learning methods. The importance of classifying geodynamic processes is noted in terms of understanding the nature of seismic phenomena, identifying their sources, assessing the potential hazard as well as their impact on the environment and the infrastructure of underground structures. The paper describes an algorithm for analyzing seismic activity based on the data obtained as the result of recording seismic events using the hardware complex and the GITS2 seismic monitoring software in a coal mine. The paper briefly examines the key artificial intelligence methods used to control and predict hazardous geodynamic phenomena. Particular attention is paid to the development of a machine learning model based on decision trees that demonstrates high accuracy in classifying seismic events.

The classification accuracy of the developed model is 98,39% on the training set and 98,41% on the test set. This result indicates the high generalization ability of the model on new data and the absence of overfitting. Testing the algorithm on new data entering the system also confirms the high accuracy in classification of seismic event types with the level of 83–93%. This highlights the efficiency of machine learning methods in mine seismic control. After its trial operation, the developed machine learning model will be implemented in the GITS2 monitoring system, that will allow classification of the incoming seismic events in automatic mode.

Keywords: mine, seismic events, seismic monitoring, artificial intelligence methods, machine learning, classification algorithm, decision trees, Catboost

For citation: Romanevich K.V., Mulev S.N. Automation of seismic events classification during seismic monitoring at a coal mine using machine learning. *Russian Mining Industry*. 2023;(5S):58–64. <https://doi.org/10.30686/1609-9192-2023-5S-58-64>

Введение

Опасные геодинамические процессы и явления представляют значительную угрозу безопасности при ведении горных работ на угольных шахтах и рудниках, строительстве и эксплуатации подземных сооружений. По мере расширения человеческой деятельности в глубинных областях земной коры, проблемы, связанные с контролем и прогнозированием геодинамических явлений, становятся все более актуальными. Обеспечение геодинамической и геоэкологической безопасности ведения работ на больших глубинах освоения месторождений полезных ископаемых, а также при строительстве и эксплуатации подземных сооружений в тектонически нарушенных зонах становится одной из наиболее важных задач в современной геотехнике.

Для обеспечения безопасной и эффективной работы подземных объектов разрабатываются новые методы прогнозирования и предотвращения катастрофических форм проявления горного давления, а также создаются современные мониторинговые системы, способные оперативно информировать о геодинамических событиях и прогнозировать их.

Одной из важных задач в этой области является определение природы геодинамических событий. Техногенные геодинамические события возникают в результате собственно горных работ или технологических взрывов на объекте мониторинга или на других объектах вблизи него. Природные геодинамические события, в свою очередь, связаны с эндогенными процессами, которые протекают в земной коре, или могут быть обусловлены кумулятивным эффектом влияния человеческой деятельности.

Правильная и оперативная классификация геодинамических событий, а также определение их уровня опасности, является важным инструментом для принятия руководящих решений и применения обоснованных защитных мероприятий. Это позволяет контролировать протекание потенциально опасных процессов, своевременно реагировать на возможные угрозы безопасности и минимизировать негативные последствия.

В последние десятилетия машинное обучение с его способностью анализировать и обрабатывать большие объемы данных стало эффективным инструментом для решения сложных проблем прогнозирования и классификации. В сфере геотехники и геодинамики применение методов машинного обучения предоставляет новые возможности для автоматического контроля и классификации геодинамических событий, что способствует более эффективному управлению рисками и предотвращению возможных аварий [1].

Цель данной работы – разработка алгоритма машинного обучения, основанного на решающих деревьях для автоматизации классификации сейсмических событий, поступающих в систему сейсмомониторинга шахты GITS2. Представлена методология разработки алгоритма и результаты его работы на обучающей и тестовой выборке, а также на вновь поступающих данных.

Анализ сейсмической активности

На ряде месторождений России проводится опытно-промышленная эксплуатация методики ВНИМИ по оценке степени удароопасности на основании данных регистрации сейсмических событий по системе сейсмопавильонов, установленных на шахтах. Анализ сейсмической активности проводится с помощью специально разработанного ВНИМИ пакета программного обеспечения GITS2, который позволяет работать с каталогами сейсмических событий, строить карты сейсмоактивности на подгружаемых планах горных работ, формировать статистические данные и др. [2; 3].

Так, например, за один год автоматизированной микросейсмической системой в условиях Шерегешского месторождения было зафиксировано 5025 сейсмических событий. 30 из зарегистрированных событий имели энергию свыше 1000 Дж. Максимальная энергия одного события составила 6 385 566 Дж. Средняя энергия сейсмических событий составила 1468 Дж. Также было зарегистрировано 788 технологических взрывов с энергией от 1000 до 3 000 000 Дж [4].

В процессе работы системы GITS2 записываются сейсмограммы сейсмических событий, зарегистрированных на контролируемом объекте, после чего оператором проводится оперативная обработка.

Под обработкой события понимается:

- определение временных границ события по каждому каналу, на сейсмограмме которого визуально можно определить начало и конец события (т.н. вступление и окончание) (рис. 1);
- расчет энергии события (выполняется автоматически после указания вступлений и окончаний);
- расчет координат гипоцентра события;
- запись полученных данных в базу данных либо удале-

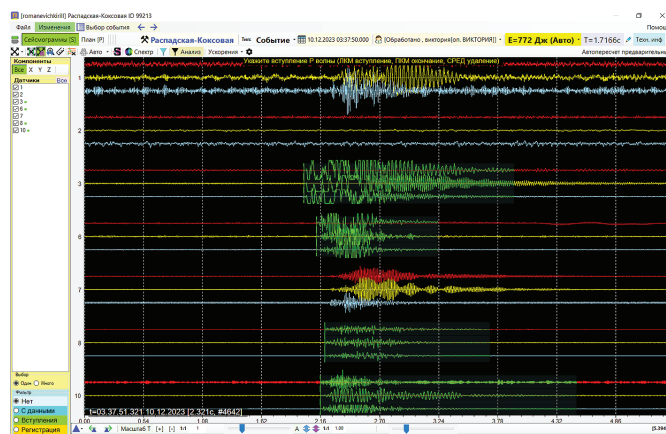


Рис. 1
Вид окна предобработки после указания примерных вступлений в программе GITS2

Fig. 1
View of the pre-processing window after specifying approximate introductions in the GITS2 software



Рис. 2
Просмотр сейсмограмм датчиков по одному в районе позиции вступления для его точной корректировки в программе GITS2

Fig. 2
Viewing seismograms of sensors one at a time in the area of the arrival position for its precise adjustment in the GITS2 software

ние из базы данных данного события, если система ошибочно зарегистрировала помеху как событие.

При просмотре одного датчика для показа будет приближен отрезок сейсмограмм этого датчика в районе вступления, здесь позиция вступления может быть откорректирована (рис. 2).

После предварительной обработки сигналов оператором каждое сейсмособытие должно быть классифицировано, для этого необходимо определить тип события (рис. 3).

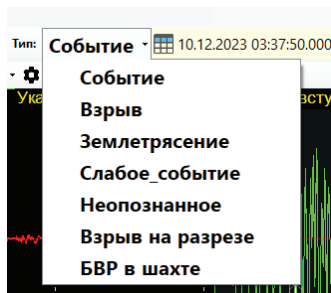


Рис. 3
Выбор типа события в программе GITS2

Fig. 3
Selecting an event type in the GITS2 software

Классификация позволяет понимать природу и источники различных сейсмических событий, а также оценивать их потенциальную опасность и влияние на окружающую среду, массив и конструкции. Список различных типов событий задается администратором индивидуально для каждой шахты.

Для верной классификации зарегистрированных сейсмических событий и минимизации неопознанных сейсмособытий на шахте необходим дополнительный оперативный сбор информации о технологических процессах как на самой шахте, так и на объектах вблизи нее, например, на ближайших разрезах и шахтах, где также проводятся технологические взрывы. Это может занимать некоторое время и вызывать задержку в определении естественной сейсмичности в пределах контролируемого массива.

Для автоматизации классификации геодинамических процессов при мониторинге сейсмоактивности на шахтах могут быть использованы современные методы искусственного интеллекта, в частности, методы глубокого обучения и методы машинного обучения. Эти методы позволяют обрабатывать и анализировать большие объемы данных с высокой скоростью и точностью, что является критически важным для эффективного мониторинга и прогноза развития

геодинамических процессов.

Методы искусственного интеллекта для контроля и прогнозирования опасных геодинамических явлений

Применение методов искусственного интеллекта для прогнозирования геодинамических процессов и явлений в шахтах и подземных сооружениях дает многообещающие результаты и имеет потенциал изменить понимание и мониторинг этих процессов. Множество современных исследований в этой области посвящено прогнозированию геодинамических явлений и краткосрочному пространственно-временному распределению сейсмических рисков в шахтах путем выявления предвестников на основе глубоких нейронных сетей, таких как двусторонние рекуррентные нейронные сети LSTM [5], ConvLSTM [6] и применение технологии Интернета вещей (IoT) [7].

Также существуют другие важные алгоритмы глубокого обучения, часто используемые для решения таких задач [8–11]: сверточные нейронные сети (CNN), рекуррентные нейронные сети (RNN), модели на основе трансформеров, глубокие автоэнкодеры, глубокое обучение с подкреплением. Комбинирование нескольких моделей глубокого обучения с использованием ансамблей методов может улучшить точность и надежность прогнозов.

Несмотря на многообещающие результаты, применение методов искусственного интеллекта также сталкивается с некоторыми проблемами, главной из которых является интерпретируемость – некоторые модели искусственного интеллекта, особенно глубокие нейронные сети, часто рассматриваются как «черные ящики», что затрудняет интерпретацию их решений и прогнозов. В областях, таких как горнодобывающая промышленность, интерпретируемость является ключевой для создания доверия к системам на основе искусственного интеллекта.

Классические методы машинного обучения, представленные в данной статье, предлагают несколько преимуществ по сравнению с нейронными сетями:

1. Классические методы машинного обучения, такие как деревья решений и случайные леса, могут обучаться быстрее, особенно на небольших наборах данных. Это может быть критически важным при ограниченных ресурсах или когда требуются быстрые результаты.
2. Многие классические методы, такие как деревья решений, обеспечивают высокую интерпретируемость, позволяя понимать принимаемые решения и объяснять результаты модели другим лицам.
3. Работа с небольшими наборами данных: если набор данных ограничен, классические методы могут быть более эффективными, чем глубокие нейронные сети, которые часто требуют большого объема данных для успешного обучения.

В данной статье описывается построение классической модели машинного обучения на реальном наборе данных и демонстрируются полученные результаты.

Модель машинного обучения, основанная на решающих деревьях

Процесс обучения включал выбор значимых характеристик сейсмограмм и базировался на решающих деревьях и случайных лесах. Эти методы широко используются в машинном обучении из-за их способности выявлять сложные взаимосвязи и паттерны в данных, что делает их эффектив-

ными для анализа важности характеристик и классификации. Алгоритм решающего дерева разделяет данные на поднаборы на основе наиболее различающих характеристик, тогда как случайный лес объединяет несколько решающих деревьев для повышения точности и снижения переобучения. Используя эти алгоритмы, модель выявляет наиболее значимые характеристики и предоставляет прогноз распределения целевой переменной для тестовой выборки.

Построение модели машинного обучения

Для демонстрации возможности автоматизации классификации сейсмических событий при мониторинге сейсмоактивности на шахтах с использованием методов машинного обучения были выбраны четыре типа событий – два техногенных («взрыв» и «взрыв на разрезе») и два естественных («событие» и «землетрясение»). Типичные сейсмограммы таких событий представлены на рис. 4.

Получение набора данных для машинного обучения начинается с извлечения из каждого сигнала характеристик, которые можно разделить на три основные категории – амплитудно-временные (28 характеристик), спек-

трально-временные (6 характеристик) и мел-спектральные (40 характеристик) параметры каждого сигнала. После этого происходит объединение в одну таблицу данных для каждого сигнала.

Полученные характеристики каждого сигнала из таблицы преобразуются в одну строку, где каждая колонка представляет собой одну характеристику сигнала для каждого датчика для каждой его компоненты (в среднем около 2000 параметров для каждого события). Этот процесс повторяется для каждого сигнала, и результаты обработки собираются в одну общую таблицу данных. Каждая строка этой таблицы соответствует одному сигналу, а колонки содержат значения извлеченных характеристик. Таким образом, после экстракции характеристик из сигналов получается одна общая таблица с данными, которая в дальнейшем используется для анализа и обучения модели машинного обучения.

Каждому типу события задается свой идентификатор, в данной работе это «события» (125 событий), «взрывы» (26 событий), «взрывы на разрезе» (150 событий) и «землетрясения» (11 событий). Всего в обучении модели и тесте участвовало 312 событий.

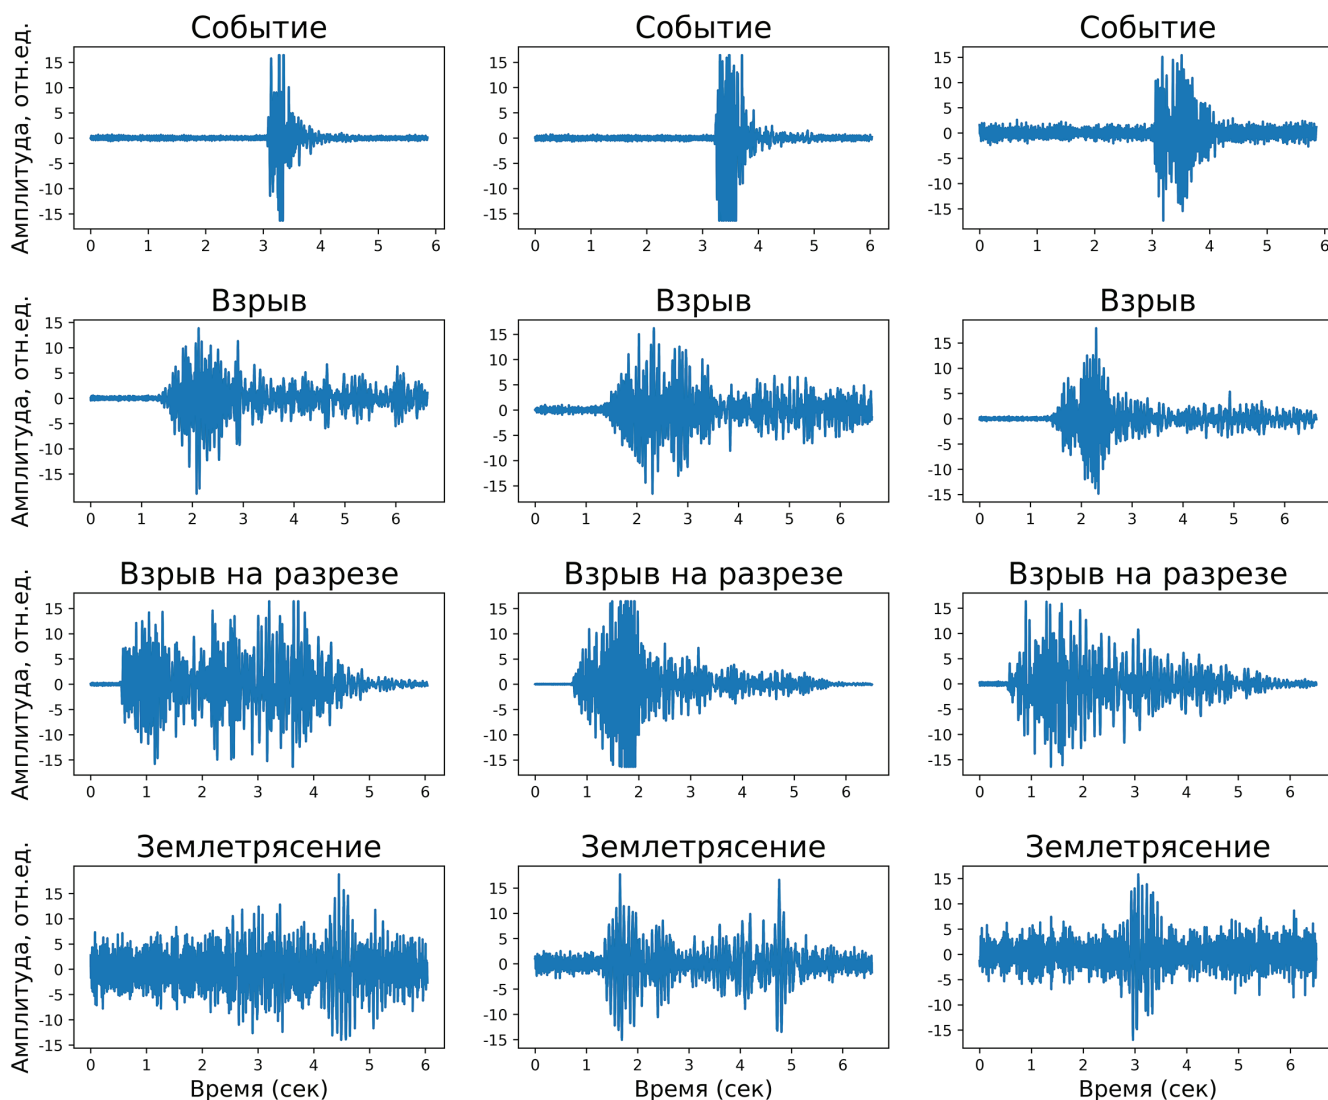


Рис. 4
Типичные сейсмограммы событий различного типа, зарегистрированные при мониторинге сейсмоактивности на шахте системой GITS2

Fig. 4
Typical seismograms of various types of the events recorded during monitoring of seismic activity in a coal mine using the GITS2 software

После подготовки набора данных с извлеченными характеристиками и целевыми значениями выборка разделяется на обучающую, валидационную и тестовую в соотношении 0,6, 0,2 и 0,2 соответственно. Целевой параметр равномерно распределяется внутри этих выборок.

С использованием библиотеки машинного обучения CatBoost [12; 13], реализованной на языке Python, была создана модель машинного обучения и обучена на обучающей выборке с применением перекрестной проверки на валидационной выборке. Процесс кросс-валидации включал разделение обучающего набора данных на 5 поднаборов. Затем модель обучалась на одном поднаборе и оценивалась на оставшихся, повторяя этот процесс для каждого поднабора. Такой подход предоставил усредненную оценку производительности модели, обеспечивая более объективную оценку ее способности к обобщению и уменьшая риск переобучения на конкретных данных. На рис. 5 показаны выводы, связанные с процессом обучения модели. Здесь представлены результаты обучения модели с использованием библиотеки CatBoost на обучающем наборе данных. Каждая строка вывода соответствует определенной итерации обучения, где модель обучается на определенном количестве деревьев (итераций).

```

0:   learn: 1.3424848   test: 1.3409347 best: 1.3409347 (0)   total: 688ms   remaining: 11m 27s
100: learn: 0.2888002   test: 0.3391951 best: 0.3391951 (100) total: 38.6s   remaining: 5m 43s
200: learn: 0.1297034   test: 0.1945264 best: 0.1945264 (200) total: 1m 22s   remaining: 5m 26s
300: learn: 0.0675802   test: 0.1409647 best: 0.1409647 (300) total: 2m 10s   remaining: 5m 2s
400: learn: 0.0434238   test: 0.1227865 best: 0.1227865 (400) total: 2m 56s   remaining: 4m 24s
500: learn: 0.0322735   test: 0.1137837 best: 0.1137837 (500) total: 3m 41s   remaining: 3m 40s
600: learn: 0.0255575   test: 0.1086486 best: 0.1086486 (600) total: 4m 25s   remaining: 2m 56s
700: learn: 0.0209463   test: 0.1054962 best: 0.1054962 (700) total: 5m 9s    remaining: 2m 12s
800: learn: 0.0175214   test: 0.1038285 best: 0.1036435 (796) total: 5m 54s   remaining: 1m 28s
900: learn: 0.0152597   test: 0.1019113 best: 0.1019113 (900) total: 6m 38s   remaining: 43.8s
999: learn: 0.0133631   test: 0.1003618 best: 0.1003119 (983) total: 7m 22s   remaining: 0us

bestTest = 0.1003118668
bestIteration = 983

Shrink model to first 984 iterations.
    
```

Рис. 5
Процесс обучения модели: learn – это оценка качества модели на обучающем наборе данных – чем меньше значение, тем лучше модель прогнозирует обучающие данные; test – это ошибка на валидационном наборе данных показывает, насколько хорошо модель обобщается на новых, не виденных ранее данных, чем меньше значение, тем лучше модель обобщается; best – это лучшее значение ошибки на тестовом наборе данных в процессе обучения модели; bestIteration – это номер итерации, на котором достигается лучшее значение ошибки на валидационном наборе данных; Shrink model to first 983 iterations: CatBoost усекает модель до 983 итерации, так как это итерация с лучшим результатом на тестовом наборе данных

Fig. 5
The model training process: 'learn' is an estimation of the quality of the model on the training dataset – the smaller the value, the better the model predicts the training data; 'test' is an error in the validation data set shows how well the model generalizes using the new, previously unseen data, the lower the value, the better the model is generalized; 'best' is the best value of the error on the test dataset in the process of the model training; 'bestIteration' is the iteration number at which the best error value is achieved on the test dataset; 'Shrink model to first 983 iterations': CatBoost truncates the model to 983 iterations as this is the iteration with the best result on the test dataset

Таким образом, процесс обучения модели начинается с ошибки на уровне 1,3409347 на обучающем наборе данных и постепенно снижается с каждой итерацией. В результате после 983 итераций лучшее значение ошибки на тестовом наборе данных составляет 0,1003118668. Ошибка в данном контексте представляет собой числовую величину, которая показывает, насколько модель отклоняется от правиль-

ных ответов на валидационной выборке. В данном случае используется среднеквадратичная ошибка (Mean Squared Error, MSE), которая вычисляет среднее значение квадратов разностей между прогнозами модели и фактическими значениями на тестовой выборке. Значение ошибки 0,1 говорит о том, что модель достаточно точно предсказывает целевые значения, и ошибается примерно на эту величину в среднем для классов 1, 2, 3 и 4.

Полученные результаты

Модель машинного обучения была применена к совмещенной обучающей и валидационной и тестовой выборке. Применение модели к совмещенной обучающей, валидационной и тестовой выборке с использованием кросс-валидации позволяет лучше оценить обобщающую способность модели на новых, неизвестных данных и сделать ее более надежной и устойчивой. Это важная практика при работе с ограниченными объемами данных помогает избежать переобучения, когда модель слишком хорошо приспособливается к обучающим данным, но плохо работает на новых данных.

Результаты работы модели на совмещенной обучающей и валидационной выборке показаны на рис. 6.

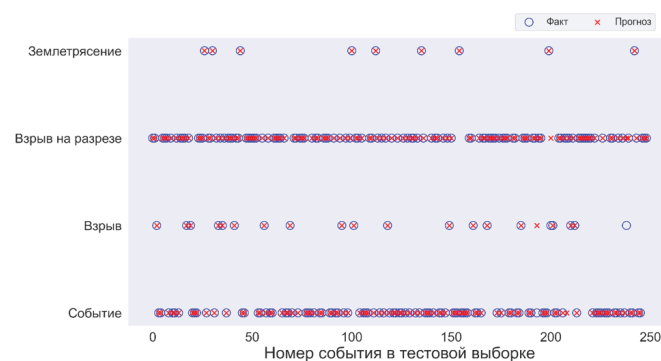


Рис. 6
Результаты работы модели на совмещенной обучающей и валидационной выборке. Из 249 событий 245 классифицированы верно, точность модели составила 98,39%

Fig. 6
Results of the model's performance on combined training and validation dataset. Out of 249 events, 245 events were classified correctly, the accuracy of the model is 98,39%

Точность модели на совмещенной обучающей и валидационной выборке в 98,39% говорит о том, что модель хорошо обучилась и способна давать правильные предсказания для подавляющего большинства событий.

Однако, помимо точности на обучающей и валидационной выборке, также важно проверить, как хорошо модель обобщается на новых, ранее не виденных ею данных (тестовая выборка). Это позволит оценить общую способность модели к обобщению и понять, насколько её результаты будут достоверными для новых данных.

Результаты работы модели на тестовой выборке показаны на рис. 7.

Точность модели на тестовой выборке составляет 98,41%. Это говорит о том, что модель хорошо обобщается на новых данных, то есть не переобучается на обучающей и валидационной выборке и способна делать точные предсказания на реальных данных.



Рис. 7
Результаты работы модели на тестовой выборке. Из 63 событий 62 классифицированы верно, точность модели составила 98,41%

Fig. 7
Results of the model's performance on the test dataset. Out of 63 events, 62 events were classified correctly, the accuracy of the model is 98,41%

Применение модели в тестовом режиме

При регистрации системой сейсмомониторинга GITS2 очередного события на контролируемой шахте – новые данные поступают в виде файлов – набора сейсмограмм в тестовую директорию. В ходе обработки сейсмограмм вновь поступивших событий из каждой сейсмограммы извлекаются амплитудные, спектральные и мел-спектральные признаки, аналогичные тем, с которыми модель работала при ее обучении.

После этого, с помощью сохраненной модели выполняется классификация типов событий для новых данных – вычисляются вероятности принадлежности каждого события к определенному типу, вероятности переводятся в проценты и представляются в виде таблицы, где для каждого события указывается вероятность принадлежности к каждому из типов, в данном примере это типы сейсмособытий – «Событие», «Взрыв», «Взрыв на разрезе» и «Землетрясение». Так, на рис. 8, а показан результат работы алгоритма классификации геодинамических процессов при мониторинге сейсмоактивности на шахте с использованием методов ма-

а)

Вероятный тип события:	Вероятность, %
Событие	0.000000
Взрыв	3.333333
Взрыв на разрезе	93.333333
Землетрясение	3.333333

б)

Вероятный тип события:	Вероятность, %
Событие	83.333333
Взрыв	3.333333
Взрыв на разрезе	13.333333
Землетрясение	0.000000

Рис. 8
Результаты работы алгоритма классификации геодинамических процессов при мониторинге сейсмоактивности на шахте с использованием методов машинного обучения для вновь поступившего в программу события типа «Взрыв на разрезе» (а), для вновь поступившего в программу события типа «Событие» (б)

Fig. 8
Results of the algorithm for classifying geodynamic processes when monitoring seismic activity in a coal mine using machine learning methods for the 'Blast in the strip mine' event type newly input into the software (a), and for the 'Event' event type newly input into the software (b)

шинного обучения для вновь поступившего в программу события типа «Взрыв на разрезе», а на рис. 8, б для вновь поступившего в программу события типа «Событие».

Заключение

Точность классификации разработанной модели на обучающей выборке составила 98,39%, а на тестовой выборке – 98,41%. Этот результат свидетельствует о высокой обобщающей способности модели на новых данных и отсутствии переобучения. Проверка алгоритма на новых данных, поступающих в систему сейсмомониторинга GITS2, также подтверждает высокую точность классификации типов сейсмических событий на уровне 83–93%. Разработанная модель машинного обучения после ее опытной эксплуатации будет внедрена в мониторинговую систему GITS2, что позволит производить классификацию поступающих сейсмических событий в автоматическом режиме.

Список литературы

1. Романевич К.В., Мулев С.Н. Применение методов машинного обучения для анализа данных электромагнитного излучения при деформировании горных пород. В кн.: *Цифровые технологии в горном деле: тезисы докладов Всерос. науч.-техн. конф., 13–16 июня 2023 г.* Апатиты: ФИЦ КНЦ РАН; 2023. С. 53–55. <https://doi.org/10.37614/978.5.91137.491.4>
2. Разумов Е.Е., Рукавишников Г.Д., Мулев С.Н., Простов С.М. Основные принципы построения систем сейсмического мониторинга при отработке удароопасных угольных пластов. *Горный журнал.* 2021;(1):8–12. <https://doi.org/10.17580/gzh.2021.01.02>
3. Рукавишников Г.Д., Мулев С.Н., Гаврилов А.Г. Опыт применения и перспективы развития системы сейсмического мониторинга ГИТС на Таштагольском железорудном месторождении. *Горная промышленность.* 2023;(S1):90–95. <https://doi.org/10.30686/1609-9192-2023-S1-90-95>
4. Разумов Е.Е., Рукавишников Г.Д., Климов В.К. Геофизический прогноз удароопасности при ведении горных работ. В кн.: *Костиков К.С. (ред.) Россия молодая: материалы 13-й Всерос. науч.-практ. конф. с международным участием, г. Кемерово, 20–23 апреля 2021 г.* Кемерово: Кузбасский государственный технический университет имени Т.Ф. Горбачева; 2021. С. 10908.1–10908.6. Режим доступа: <https://science.kuzstu.ru/wp-content/Events/Conference/RM/2021/RM21/pages/Articles/010908.pdf>
5. Di Y., Wang E. Rock burst precursor electromagnetic radiation signal recognition method and early warning application based on recurrent neural networks. *Rock Mechanics and Rock Engineering.* 2021;54(3):1449–1461. <https://doi.org/10.1007/s00603-020-02314-w>
6. Qiu L., Li Z., Wang E., Liu Z., Ou J., Li X. et al. Characteristics and precursor information of electromagnetic signals of mining-induced coal and gas outburst. *Journal of Loss Prevention in the Process Industries.* 2018;54:206–215. <https://doi.org/10.1016/j.jlp.2018.04.004>
7. Zhang J. Exploration on coal mining-induced rockburst prediction using Internet of things and deep neural network. *The Journal of Supercomputing.* 2022;78(12):13988–14008. <https://doi.org/10.1007/s11227-022-04424-4>
8. Di Y., Wang E., Li Z., Liu X., Huang T., Yao J. Comprehensive early warning method of microseismic, acoustic emission, and electromagnetic radiation signals of rock burst based on deep learning. *International Journal of Rock Mechanics and Mining Sciences.* 2023;170:105519. <https://doi.org/10.1016/j.ijrmms.2023.105519>

9. Li X., Chen S., Wang E., Li Z., Rockburst mechanism in coal rock with structural surface and the microseismic (MS) and electromagnetic radiation (EMR) response. *Engineering Failure Analysis*. 2021;124:105396. <https://doi.org/10.1016/j.engfailanal.2021.105396>
10. Huang L., Li J., Hao H., Li X. Micro-seismic event detection and location in underground mines by using Convolutional Neural Networks (CNN) and deep learning. *Tunnelling and Underground Space Technology*. 2018;81:265–276. <https://doi.org/10.1016/j.tust.2018.07.006>
11. Pu Y., Apel D.B., Liu V., Mitri H. Machine learning methods for rockburst prediction-state-of-the-art review. *International Journal of Mining Science and Technology*. 2019;29(4):565–570. <https://doi.org/10.1016/j.ijmst.2019.06.009>
12. Hancock J.T., Khoshgoftaar T.M. CatBoost for big data: an interdisciplinary review. *Journal of Big Data*. 2020;7:94. <https://doi.org/10.1186/s40537-020-00369-8>
13. Ibrahim A.A., Raheem R.L., Muhammed M.M., Abdulaziz R.O., Ganiyu S.A. Comparison of the CatBoost classifier with other machine learning methods. *International Journal of Advanced Computer Science and Applications*. 2020;11(11):738–748. <https://doi.org/10.14569/IJACSA.2020.0111190>

References

1. Romanevich K.V., Mulev S.N. Application of machine learning methods for analyzing electromagnetic radiation data during rock deformation. In: *Digital technologies in mining: Abstracts of reports of the All-Russian scientific and technical conference, June 13–16, 2023*. Apatity: Mining Institute Kola Science Centre of the Russian Academy of Sciences; 2023, pp. 53–55. (In Russ.) <https://doi.org/10.37614/978.5.91137.491.4>
2. Razumov E.E., Rukavishnikov G.D., Mulev S.N., Prostov S.M. Basic principles for building seismic monitoring systems in rockburst-hazardous coal seam mining. *Gornyi Zhurnal*. 2021;(1):8–12. (In Russ.) <https://doi.org/10.17580/gzh.2021.01.02>
3. Rukavishnikov G.D., Mulev S.N., A. Gavrilov G. Experience of application and prospects for the development of the GITS seismic monitoring system at the Tashtagolsky iron ore deposit. *Russian Mining Industry*. 2023;(1 Suppl.):90–95. (In Russ.) <https://doi.org/10.30686/1609-9192-2023-S1-90-95>
4. Razumov E.E., Rukavishnikov G.D., Klimko V.K. Geophysical forecast of impact hazard during mining operations. In: *Kostikov K.S. (ed.) Young Russia: Materials of the 13 All-Russian scientific and practical conference with international participation, Kemerovo, April 20–23, 2021*. Kemerovo: T. F. Gorbachev Kuzbass State Technical University; 2021, pp. 10908.1–10908.6. (In Russ.) Available at: <https://science.kuzstu.ru/wp-content/Events/Conference/RM/2021/RM21/pages/Articles/010908.pdf>
5. Di Y., Wang E. Rock burst precursor electromagnetic radiation signal recognition method and early warning application based on recurrent neural networks. *Rock Mechanics and Rock Engineering*. 2021;54(3):1449–1461. <https://doi.org/10.1007/s00603-020-02314-w>
6. Qiu L., Li Z., Wang E., Liu Z., Ou J., Li X. et al. Characteristics and precursor information of electromagnetic signals of mining-induced coal and gas outburst. *Journal of Loss Prevention in the Process Industries*. 2018;54:206–215. <https://doi.org/10.1016/j.jlp.2018.04.004>
7. Zhang J. Exploration on coal mining-induced rockburst prediction using Internet of things and deep neural network. *The Journal of Supercomputing*. 2022;78(12):13988–14008. <https://doi.org/10.1007/s11227-022-04424-4>
8. Di Y., Wang E., Li Z., Liu X., Huang T., Yao J. Comprehensive early warning method of microseismic, acoustic emission, and electromagnetic radiation signals of rock burst based on deep learning. *International Journal of Rock Mechanics and Mining Sciences*. 2023;170:105519. <https://doi.org/10.1016/j.ijrmms.2023.105519>
9. Li X., Chen S., Wang E., Li Z., Rockburst mechanism in coal rock with structural surface and the microseismic (MS) and electromagnetic radiation (EMR) response. *Engineering Failure Analysis*. 2021;124:105396. <https://doi.org/10.1016/j.engfailanal.2021.105396>
10. Huang L., Li J., Hao H., Li X. Micro-seismic event detection and location in underground mines by using Convolutional Neural Networks (CNN) and deep learning. *Tunnelling and Underground Space Technology*. 2018;81:265–276. <https://doi.org/10.1016/j.tust.2018.07.006>
11. Pu Y., Apel D.B., Liu V., Mitri H. Machine learning methods for rockburst prediction-state-of-the-art review. *International Journal of Mining Science and Technology*. 2019;29(4):565–570. <https://doi.org/10.1016/j.ijmst.2019.06.009>
12. Hancock J.T., Khoshgoftaar T.M. CatBoost for big data: an interdisciplinary review. *Journal of Big Data*. 2020;7:94. <https://doi.org/10.1186/s40537-020-00369-8>
13. Ibrahim A.A., Raheem R.L., Muhammed M.M., Abdulaziz R.O., Ganiyu S.A. Comparison of the CatBoost classifier with other machine learning methods. *International Journal of Advanced Computer Science and Applications*. 2020;11(11):738–748. <https://doi.org/10.14569/IJACSA.2020.0111190>

Информация об авторах

Романевич Кирилл Викторович – кандидат технических наук, ведущий научный сотрудник, Научно-исследовательский институт горной геомеханики и маркшейдерского дела – межотраслевой научный центр «ВНИМИ», г. Санкт-Петербург, Российская Федерация; e-mail: romanevichkirill@gmail.com

Мулёв Сергей Николаевич – директор по науке, Научно-исследовательский институт горной геомеханики и маркшейдерского дела – межотраслевой научный центр «ВНИМИ», г. Санкт-Петербург, Российская Федерация; e-mail: info@vnimi.ru

Information about the authors

Kirill V. Romanevich – Cand. Sci. (Eng.), Leading Research Associate, Research Institute of Mining Geomechanics and Mine Surveying – Interdisciplinary Research Center “VNIMI”, St. Petersburg, Russian Federation; e-mail: romanevichkirill@gmail.com

Sergey N. Mulev – R&D Director, Research Institute of Mining Geomechanics and Mine Surveying – Interdisciplinary Research Center “VNIMI”, St. Petersburg, Russian Federation; e-mail: info@vnimi.ru

Article info

Received: 31.10.2023

Revised: 22.11.2023

Accepted: 27.11.2023

Информация о статье

Поступила в редакцию: 31.10.2023

Поступила после рецензирования: 22.11.2023

Принята к публикации: 27.11.2023