

РАЗРАБОТКА КЛАССИФИЦИРУЮЩЕЙ МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОБРАБОТКИ СИГНАЛОВ СИСТЕМЫ «PROGNOZ-ADS» НА РУДНИКЕ «НИКОЛАЕВСКИЙ»

Грунин А.П., Константинов А.В., Сидляр А.В.

*Институт горного дела ДВО РАН, г. Хабаровск
lexx188@mail.ru*

Современные системы контроля горного давления представляют собой передовые инструменты для оценки и управления геомеханическим состоянием породного массива [1, 2].

Автоматизированная система контроля горного давления «Prognoz-ADS» позволяет регистрировать и определять параметры акустических сигналов в диапазоне от 0,5 до 12 кГц, выделять и контролировать потенциально удароопасные зоны в массиве горных пород. Системы установлены в подземных выработках на месторождениях «Антей», Мало-Тулукуевское, Николаевское, Южное и на рудниках КФ АО «Апатит».

Система фиксирует значительный объем сигналов, которые условно делятся 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.

Зарегистрированные сигналы служат первичными данными, на основе которых формируются события – группы сигналов, излученных одним источником. На основе времени регистрации сигналов возможен расчет координат источника акустической эмиссии [3, 4]. Далее из этих событий выделяются акустически активные зоны. Анализ таких зон впоследствии позволяет определять удароопасные участки.

Для точного прогнозирования и контроля удароопасности критически важна классификация акустических сигналов по указанным категориям. Учитывая масштабы мониторинга и возрастающие объёмы данных (за год система может зарегистрировать 3,5 миллиона импульсов), ручная обработка специалистами становится неэффективной – это обусловило разработку автоматизи-

рованной системы классификации на основе методов машинного обучения.

Для решения задачи классификации методом машинного обучения необходимо выполнение 3 основных этапов:

1. Создание размеченного набора данных, на которых будет обучаться и проверяться модель;
2. Определение необходимых признаков, на основе которых модель будет принимать решение о классификации;
3. Выбор модели, обучение и проверка точности классификации.

Для создания размеченного набора данных была использована база данных системы «Prognoz-ADS» Николаевского рудника за 2022 год [5]. Для построения выборки применялись опыт специалистов по ручной обработке сигналов в базе данных и специально разработанное ПО «GeoFiltration». Полученная в результате работы обучающая выборка включает: 15 тысяч взрывных импульсов, 102 тысячи буровых импульсов, 74 тысячи импульсов естественной акустической эмиссии.

На следующем этапе было создано пространство признаков. Часть признаков рассчитываются на стороне регистрирующего датчика в момент регистрации каждого импульса. В эту группу входят: амплитуда сигнала, длительность сигнала, длительность фронта сигнала, порог регистрации, площадь сигнала, параметр MARSE [6].

Для надежной классификации сигналов акустической эмиссии требуется расширение списка признаков. Дополнительные признаки могут быть рассчитаны исходя из показателя времени регистрации импульса. Таким образом были сформированы следующие признаки:

Глобальная плотность импульсов – число импульсов, зарегистрированных всеми доступными геофонами в интервале времени T от момента регистрации исходного импульса.

Локальная плотность импульсов – число импульсов, зарегистрированных конкретным геофоном в интервале времени T от момента регистрации исходного импульса.

Время до ближайшего сигнала – параметр, позволяющий определять периодичность в поступлении сигналов и тем самым определять периодические события, которые характерны для буровой активности.

Итого на данный момент предполагается использовать 9 признаков.

При большом количестве признаков возможно применение специальных алгоритмов снижения размерности данных. На рисунке 1 представлен график свернутого в двумерное пространство алгоритмом UMAP [7] набора 9 признаков. Классы естественной акустической эмиссии (зеленый цвет), буровых работ (желтый цвет) и взрывных работ (красный цвет) хоть и разделены, но имеют пересечения.




Рис. 1. График свернутого в двумерное пространство набора 9 признаков

С целью проверки корректности выбора и обработки признаков была протестирована одна из моделей машинного обучения на размеченной части базы данных. В качестве модели был выбран метод случайного леса [8].

Размеченная база данных была разделена на две части. 70% составили данные для обучения модели случайного леса. Оставшиеся 30% для проверки корректности результата. Также модель случайного леса позволяет определять важность каждого признака. Отчет классификации для модели случайного леса демонстрирует очень хорошие результаты по точности, которая составляет 96,54%. На рисунке 2 представлена апробация полученной модели на участке базы неразмеченных данных.




Рис. 2. Демонстрация работы модели

Литература

1. Małkowski P., Niedbalski Z. A comprehensive geomechanical method for the assessment of rockburst hazards in underground mining // International Journal of Mining Science and Technology. 2020. Vol. 30. № 3. P. 345-355.
2. Абетов А., Кудайбергенова С., Сидоров В. Creation of geodynamic polygons and technologies for conducting geodynamic monitoring in the hydrocarbon fields // Engineering Journal of Satbayev University. 2021. Vol. 143. № 2. P. 3-13.
3. 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. С. 13-20.
4. Zhou Z., Rui Y., & Cai X., Lan R., Cheng R. A Closed-Form Method of Acoustic Emission Source Location for Velocity-Free System Using Complete TDOA Measurements // Sensors. 2020. Vol. 20. № 12. P. 1-14.
5. Ломов М.А., Сидляр А.В., Константинов А.В., Грунин А.П. Геомеханические проблемы отработки нижних горизонтов месторождения Южное (Приморский край) // Горный информационно-аналитический бюллетень. 2023. № 12-2. С. 87-99.
6. Bechhoefer E., Qu Y., Zhu J., He D. Signal Processing Techniques to Improve an Acoustic Emissions Sensor // Proceedings of the Annual Conference of the Prognostics and Health Management Society. 2013. Vol. 4. P. 581-588.
7. McInnes L., Healy J., Saul N., Grossberger L. UMAP: Uniform Manifold Approximation and Projection // Journal of Open-Source Software. 2018. Vol. 3. № 29. P. 861.
8. Mazumder P., Baruah 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. P. 19-25.