

АНАЛИЗ СЕЙСМОАКУСТИЧЕСКИХ ДАННЫХ СИСТЕМЫ PROGNOZ-ADS НА РУДНИКЕ НИКОЛАЕВСКИЙ

Константинов А.В., Лештаев В.С., Грунин А.П.

*Институт горного дела ДВО РАН, г. Хабаровск
alex-sdt@yandex.ru*

Актуальная задача состоит в повышении эффективности выделения сигналов акустической эмиссии. Для ее решения планируется использовать комплексный подход, основанный на разработке фильтрационных критериев, позволяющих с высокой степенью вероятности выделить часть сигналов по каждой из классификационных групп. Далее по сформированным выборкам планируется создать математическую модель на основе алгоритмов машинного обучения, позволяющую отфильтровать большинство оставшихся «сложных» в интерпретации сигналов.

Задачу классификации можно решать множеством методов машинного обучения, включая не только нейросетевые модели [1-3], но также и классические алгоритмы, например, случайный лес или градиентный бустинг [4, 5]. Эти подходы требуют качественной подготовки исходных данных. При подготовке признакового пространства следует учитывать возможные выбросы в данных, большой разброс значений, корреляцию параметров и наличие нулевых значений.

Для рассмотрения структуры регистрируемых системой Prognoz-ADS данных рассмотрим основные параметры сигналов Николаевского рудника предприятия АО «Дальполиметалл» за 2019 г. [6] (табл. 1).

Таблица 1. Параметры сигналов рудника Николаевский за 2019 г.

Всего – 6725 сигналов	Амплитуда, кв	Длительность, кв	Длит. фронта, кв	Порог, кв	Площадь	MARSE
Среднее значение	14496	1144	457	4966	1162867	431729
Станд. отклонение	44209	517	234	884	2577545	1262839
Мин. значение	280	370	92	3261	38825	12667
Медианное значение	2588	1001	428	4795	419840	103340
Макс. значение	524256	5561	2098	9970	67913528	30491424




Рис. 1. Пример сигналограммы импульса

Большинство представленных в таблице параметров получено из сигналограмм импульсов, пример которой представлен на рисунке 1.

Как можно заметить из рисунка 2, у некоторых признаков сигналов наблюдаются достаточно длинные «хвосты». Эти сигналы с завышенными значениями могут в дальнейшем ухудшать качество обучаемой модели.

Особый интерес представляет подход к классификации сигналов, связанный с анализом временных рядов при помощи элементов рекомендательных систем, свёрточных и рекуррентных нейронных сетей. Использование таких моделей осложняется разной длиной регистрируемых сигналов, которые требуется разбивать на отдельные части при помощи скользящего окна, что приведет к разному количеству фрагментов. Для

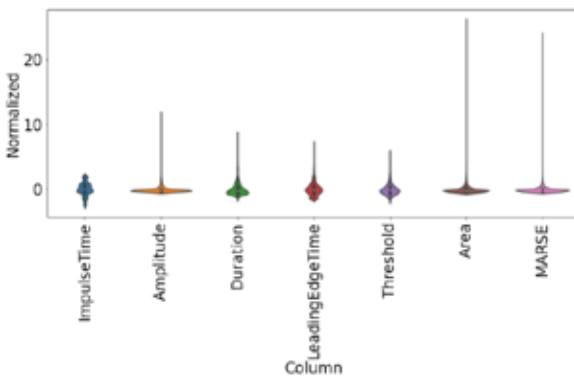


Рис. 2. Распределение параметров сигналов, нормированных по среднему значению

решения этой проблемы предлагается несколько подходов: ограничение количества частей, адаптивный размер окна или получение комплексного параметра, характеризующего всю сигналограмму.

Создание математической модели на основе методов машинного обучения это комплексный исследовательский процесс. Он включает многократное выдвижение гипотез, о том каким образом сформировать обучающую выборку в текущей итерации, чтобы повысить качество разрабатываемой модели. В каждом таком случае будет либо изменяться структура признакового пространства, либо его качественный состав.

Исследования проводились с использованием ресурсов Центра коллективного пользования научным оборудованием «Центр обработки и хранения научных данных Дальневосточного отделения Российской академии наук», финансируемого Российской Федерацией в лице Министерства науки и высшего образования РФ по проекту № 075-15-2021-663.

Литература

1. Сергунин М.П., Еременко В.А. Обучение нейронной сети предсказывать параметры сдвижения горных пород налегающей толщи на основании данных о трещиноватости массива на примере рудника «Заполярный» // Горный информационно-аналитический бюллетень. 2019. № 10. С. 106–116. DOI: 10.25018/0236-1493-2019-10-0-106-116.
2. Hong K, Han E, Kang K. Determination of geological strength index of jointed rock mass based on image processing. // Journal of Rock Mechanics and Geotechnical Engineering. 2017. doi: 10.1016/j.jrmge.2017.05.001
3. Thibaut Perola, Michael Gharbib, Marine A. Denollec. Convolutional Neural Network for Earthquake Detection and Location // Geophysics. 2017. doi.org/10.48550/arXiv.1702.02073
4. Yuanyuan Pu, Derek B. Apel, Victor Liu, Hani Mitri. Machine learning methods for rockburst prediction-state-of-the-art review // International Journal of Mining Science and Technology. 2019. N 29. P. 565-570.
5. Liang WZ, Sari YA, Zhao GY, McKinnon S, Wu H. Probability Estimates of Short-Term Rockburst Risk with Ensemble Classifiers // Rock Mechanics and Rock Engineering. 2021. 54. P. 1799–1814. doi.org/10.1007/s00603-021-02369-3.
6. Свидетельство о государственной регистрации базы данных № 2021622135 Российская Федерация. База данных Nik-Dalpolimetall системы геомеханического мониторинга Prognoz-ADS: № 2021621807: заявл. 01.09.2021; опубл. 13.10.2021 / П.А. Аникин, А.А. Терешкин, А.В. Сидляр, М.И. Рассказов, А.В. Константинов; заявитель Федеральное государственное бюджетное учреждение науки Хабаровский Федеральный исследовательский центр Дальневосточного отделения Российской академии наук. EDN OAAOHL.