

О МЕТОДЕ ОБРАБОТКИ ДАННЫХ СЕЙСМИЧЕСКОГО И ДЕФОРМАЦИОННОГО МОНИТОРИНГА ПРИ ВЕДЕНИИ ПОДЗЕМНЫХ ГОРНЫХ РАБОТ НА ПРИМЕРЕ КИКУСВУМЧОРРСКОГО МЕСТОРОЖДЕНИЯ АО «АПАТИТ»

А.П. Господариков¹, К.В. Морозов¹, И.Е. Ревин¹

¹ Санкт-Петербургский горный университет, Санкт-Петербург, Россия, e-mail: revine@inbox.ru

Аннотация: Задачей настоящего исследования является разработка метода оценки результатов мониторинга геомеханических процессов в массиве горных пород на примере Объединенного Кировского рудника АО «Апатит». Задача прогнозирования основных параметров напряженного состояния массива горных пород, как и любая другая проблема, возникающая в процессе работы с большими массивами данных, зависит как от выбора числа, так и от типа аппроксимирующих функций. Несмотря на значительное число формальных метрик качества и способов оценки параметров, для каждого конкретного массива данных аппроксимирующие модели и критерии должны подбираться индивидуально. В результате проведения подземных горных работ в массиве горных пород происходит изменение его естественного напряженного состояния. Изложены алгоритмы машинного обучения в прикладных задачах геомеханики и геоинформатики. Сопоставляя график ведения горных работ и данные сейсмической активности с временными рядами деформаций, основанных на данных деформационного мониторинга, можно получить функциональную взаимосвязь, которая позволяет прогнозировать распределение деформаций в массиве горных пород. Приводятся результаты вычислительного эксперимента, иллюстрирующего возможность и целесообразность применения алгоритмов машинного обучения при решении задач геомеханики.

Ключевые слова: алгоритм, градиентный бустинг, мониторинг, Хибинские апатит-нефелиновые месторождения, геоинформатика.

Для цитирования: Господариков А. П., Морозов К. В., Ревин И. Е. О методе обработки данных сейсмического и деформационного мониторинга при ведении подземных горных работ на примере Кикусвумчоррского месторождения АО «Апатит» // Горный информационно-аналитический бюллетень. – 2019. – № 8. – С. 157–168. DOI: 10.25018/0236-1493-2019-08-0-157-168.

A method of data interpretation in seismicity and deformation monitoring in underground mining in terms of the Kukisvumchorr deposit of Apatit company

A.P. Gospodarikov¹, K.V. Morozov¹, I.E. Revina¹

¹ Saint-Petersburg Mining University, Saint-Petersburg, Russia, e-mail: revine@inbox.ru

Abstract: The objective of this study is to develop an assessment method for geomechanical monitoring in rocks in terms of the Kirov Mine, Apatit company. Prediction of basic parameters of rock mass stress state, as any other problem arising in data bulk handling, depends both on selection

of the number and type of approximating functions. Despite a collection of formal quality metrics and estimation techniques, the approximating models and criteria should be selected individually for each specific array of data. Underground mining alters natural stress state in rocks. This article sets forth algorithms of machine learning in applied problems of geomechanics and geo-information science. Correlation of mine operating schedules and seismic activity data with deformation time-series obtained from deformation monitoring can produce a functional relationship for prediction of strain distribution in rock mass. The article describes the results of the computational experiment which illustrates feasibility and advisability of using machine learning algorithms in solving of geomechanical problems.

Key words: algorithm, gradient boosting, monitoring, Khibiny apatite–nepheline deposits, geo-information science.

For citation: Gospodarikov A. P., Morozov K. V., Revin I. E. О методе обработки данных сейсмического и деформационного мониторинга при ведении подземных горных работ на примере Киккусвумчоррского месторождения АО «Апатит». *MIAB. Mining Inf. Anal. Bull.* 2019;(8):157-168. [In Russ]. DOI: 10.25018/0236-1493-2019-08-0-157-168.

Введение

Принятие обоснованных технологических решений тесно связано с дальнейшим совершенствованием и развитием известных методов исследования напряженного состояния массива горных пород, учитывающих в том числе нелинейный характер процесса их деформирования. При исследовании напряженного состояния массива горных пород в его структуре можно выявить определенные закономерности [1]. Получение надежных прогнозных оценок значений компонентов тензоров напряжений, деформаций и вектора перемещений техногенно-нарушенного массива горных пород является весьма актуальной научно-технической задачей. Решение такой задачи позволит предотвратить опасные проявления горного давления в горных

выработках, повысить безопасность ведения горных работ и минимизировать затраты на проведение и поддержание горных выработок в течение всего срока их эксплуатации.

Объект исследования

Объектом исследования является Объединенный Кировский рудник КФ АО «Апатит». В рамках договора между Санкт-Петербургским горным университетом и АО «Апатит» на блоке 7/10 горизонта +170 в течение двух лет проводился деформационный мониторинг. Формат данных, полученных в ходе мониторинга, приведен в табл. 1.

На горном предприятии АО «Апатит» в течение долгого периода службой прогноза и предотвращения горных ударов проводился ряд региональных и локаль-

Таблица 1

Пример формата таблицы деформационного мониторинга
Example of deformation monitoring table format

Номер датчика	Величина смещения датчика по оси X_1	Величина смещения датчика по оси X_2	Величина смещения датчика по оси Y_1	Величина смещения датчика по оси Y_2	Величина смещения датчика по оси Z	Дата регистрации смещения датчика
№	X_1 , мкм	X_2 , мкм	Y_1 , мкм	Y_2 , мкм	Z , мкм	Дата, мкм
5	90	70	80	130	0	23.11.2018 12:41:38
5	90	72	81	130	0	23.11.2018 12:36:38

Таблица 2

Пример формата таблицы сейсмического мониторинга*Example of seismic monitoring table format*

Дата регистрации сейсмического события	Класс сейсмического события	Координата сейсмического события по оси X	Координата сейсмического события по оси Y	Координата сейсмического события по оси Z	Величина энергии сейсмического события	Средняя величина энергии сейсмического события
ELocTime	ETypeId	EX	EY	EZ	EEnergy	EEnergySTD
02.11.2018	13	1206,421	502,3779	-7,84479	1529,814	1163,498703
02.11.2018	0	2204,33	464,1606	-148,638	388,1517	35,7682159
02.11.2018	13	3052,182	586,7765	73,39877	17624,06	21705,11937

ных видов мониторинга, среди которых выделяется сейсмический. Упрощенный формат данных приведен в табл. 2.

Задача исследования

Задачей настоящего исследования является сопоставление данных сейсмического и деформационного мониторинга с точки зрения разработки алгоритма прогноза опасных геодинамических явлений. Сопоставление, анализ и прогноз данных предлагается выполнять на основе алгоритмов машинного обучения, а именно: алгоритм кластеризации методом «K-means», алгоритм двойного экспоненциального сглаживания, известный как уравнение Хольта, и алгоритм градиентного бустинга [2].

Методология исследования

В качестве методологии исследования используется анализ временного ряда значений деформаций в изучаемом массиве горных пород.

В нашем случае временной ряд (или ряд динамики) — это собранный в разные моменты времени статистический материал значений каких-либо параметров (в простейшем случае одного) исследуемого процесса [3]. Каждая единица статистического материала называется измерением или отсчетом; также допустимо называть его уровнем на указанный момент времени. Во временном ряде для каждого отсчета должно быть

указано время измерения или номер измерения по порядку. Временной ряд существенно отличается от простой выборки данных, так как при таком анализе учитывается взаимосвязь измерений со временем, а не только статистическое разнообразие и статистические характеристики выборки.

Причем анализ временных рядов — это совокупность математико-статистических методов анализа, предназначенных для выявления структуры временных рядов и для их прогнозирования. К ним, в частности, и относятся методы регрессионного анализа. Выявление структуры временного ряда необходимо для построения математической модели исследуемого явления-источника анализируемого временного ряда.

На основе алгоритмов машинного обучения, в работе построена математическая модель временного ряда значений деформаций в исследуемом массиве и получена функциональная зависимость изменения значений деформаций в массиве горных пород с течением времени.

Для получения необходимой функциональной зависимости задействованы два алгоритма, в которых используются формулы простого экспоненциального сглаживания и двойного экспоненциального сглаживания.

Формула простого экспоненциально-го сглаживания имеет вид:

$$\hat{y}_t = \alpha \cdot y_t + (1 - \alpha) \cdot \hat{y}_{t-1} \quad (1)$$

Здесь модельное значение \hat{y}_t представляет собой средневзвешенную величину между текущим истинным y_t и предыдущим модельным \hat{y}_{t-1} значениями. Весовой коэффициент α выполняет роль сглаживающего фактора, определяющего, как быстро «забывается» последнее доступное истинное наблюдение. Чем меньше значение α , тем больше влияние оказывают предыдущие модельные значения, и тем сильнее сглаживается ряд.

Экспоненциальная зависимость (1) скрывается в рекурсивности функции — каждый раз предыдущее модельное значение \hat{y}_{t-1} умножается на величину $(1 - \alpha)$, которое, в свою очередь, также содержало в себе множитель $(1 - \alpha)$.

Формула двойного экспоненциального сглаживания имеет вид [4]:

$$\begin{aligned} \ell_x &= \alpha y_x + (1 - \alpha)(\ell_{x-1} + b_{x-1}), \\ b_x &= \beta(\ell_x - \ell_{x-1}) + (1 - \beta)b_{x-1}, \\ \hat{y}_{x+1} &= \ell_x + b_{x-1}. \end{aligned} \quad (2)$$

В данных зависимостях (2) сглаживание временного ряда определяют два коэффициента: α , отвечающий за сглаживание значений уровня ℓ (level, intercept) и β , отвечающий за сглаживание значений тренда b (trend, slope). Чем больше значения этих коэффициентов, тем больший вес приобретают последние наблюдения, тем самым менее сглаженным окажется построенный модельный ряд.

Уровень или ожидаемое значение ряда предсказывается при помощи простого экспоненциального сглаживания; такое же экспоненциальное сглаживание применяется и к тренду.

Таким образом, формируется набор функций:

- первая функция описывает уровень, зависящий, как и прежде, от текущего значения ряда, а второе слагаемое

разбивается на предыдущие значения уровня и тренда;

- вторая функция отвечает за тренд, зависящий от изменения уровня на текущем шаге и от предыдущего значения тренда, а в роли веса в экспоненциальном сглаживании выступает коэффициент β . Итоговое значение представляет собой сумму модельных значений уровня и тренда.

Задачу восстановления функции предполагается решать в общем контексте «обучения с учителем». Имеется набор пар признаков x и целевых переменных $y\{(x_i, y_i) \mid i = 1, \dots, n\}$ для получения искомым функциональной зависимости $y = f(x)$. Используется ее приближение в виде $\hat{f}(x)$. Для получения приближения вводится функция потерь $L(y, f(x))$, которую необходимо минимизировать [4–7]:

$$\hat{f}(x) = \operatorname{argmin} L(y, f(x)). \quad (3)$$

Приближение $\hat{f}(x)$ — результат минимизации функции потерь исходных данных:

$$\hat{f}(x) = \operatorname{argmin}_{x,y} [L(y, f(x))], \quad (4)$$

где $E(x, y)$ — условное математическое ожидание для имеющихся у нас данных. Пространство поиска ограничивается вектором конкретного параметризованного семейства функций $f(x, \theta)$, $\theta \in \mathbb{R}^d$. Таким образом, сводим исходную задачу к оптимизации значений параметров:

$$\begin{cases} \hat{f}(x) = f(x, \hat{\theta}) \\ \hat{\theta} = \operatorname{argmin}_{x,y} [L(y, f(x))] \end{cases} \quad (5)$$

Аналитические решения для получения оптимальных значений параметров θ существуют достаточно редко, поэтому такие параметры обычно приближают итерационно. Сначала выписывается эмпирическая функция потерь $L_\theta(\hat{\theta})$, показывающая насколько оптимальна их оценка по имеющимся данным. Затем выписывается приближение параметров θ за число M итераций в виде суммы:

$$\begin{cases} \hat{\theta} = \sum_{i=1}^M \hat{\theta}_i, \\ L_{\theta}(\hat{\theta}) = \sum_{i=1}^N L(y_i, f(x_i, \hat{\theta}_i)) \end{cases} \quad (6)$$

Далее выбирается подходящий итерационный алгоритм, применяемый для решения задачи минимизации. В качестве такого алгоритма в работе используется алгоритм градиентного спуска. Сначала необходимо вычислить градиент $\nabla L_{\theta}(\hat{\theta})$ и суммировать его с итерируемой оценкой $\hat{\theta}_i$ вдоль градиента (со знаком минус).

Таким образом, вычислительный алгоритм организован следующим образом:

- инициализировать начальное приближение параметров $\hat{\theta} = \hat{\theta}_0$;
- для каждой итерации $t = 1, \dots, M$ вычислить градиент функции потерь $\nabla L_{\theta}(\hat{\theta})$ при текущем приближении параметра $\hat{\theta}$.

$$\nabla L_{\theta}(\hat{\theta}) = \left[\frac{\partial L(y, f(x, \theta))}{\partial \theta} \right]_{\theta = \hat{\theta}} ;$$

- задать текущее итерационное приближение $\hat{\theta}_t$ на основе значения вычисленного градиента

$$\hat{\theta}_t \leftarrow \nabla L_{\theta}(\hat{\theta}) ;$$

- обновить приближение параметров $\hat{\theta}$, сохранив его

$$\hat{\theta} \leftarrow \hat{\theta} + \hat{\theta}_t = \sum_{i=0}^M \hat{\theta}_i .$$

Зная значение градиента функции потерь, можно вычислить его значение для заданных данных. Обучение модели заключается в том, чтобы наши предсказания были наиболее скоррелированными со значением градиента (со знаком минус). И для классификации, и для регрессии, и для ранжирования применяется процедура минимизации квадрата разности между псевдо-остатками r и полученными предсказаниями.

Экспериментальные результаты

На рис. 1 приведен пример графического двумерного представления сейсмического мониторинга в пределах Кировского рудника, позволяющий определить динамику сейсмических процессов в массиве горных пород за период наблюдения.

Как видно из приведенного графика сейсмического мониторинга 2018 г., в массиве можно выделить 2 «крупных» сейсмических события: 17 февраля в

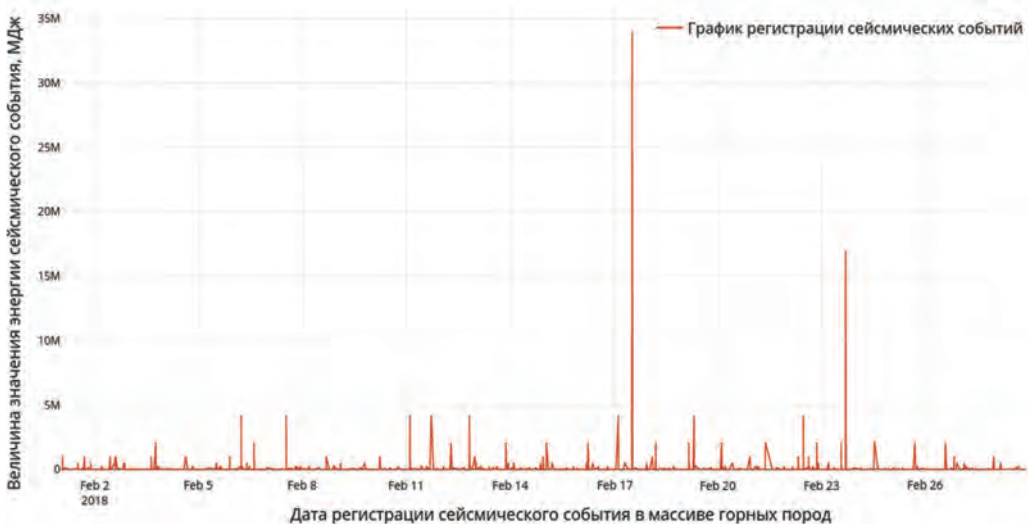


Рис. 1. Данные сейсмического мониторинга Кировского рудника за февраль 2018 г.

Fig. 1. Seismic monitoring data of the Kirov mine JSC «Apatit» for February 2018

12:23 — интенсивность 34 МДж и 23 февраля в 16:31 — интенсивность 17 МДж.

Построим две трехмерные модели массива и отметим на них координаты сейсмических событий с определенными значениями энергии. Для одной модели выберем все сейсмические события со значением энергии от 50 до 500 кДж (рис. 2). Для второй модели, будем использовать сейсмические события со значением энергии больше 15 МДж (рис. 3).

Оси X и Y — оси координат точек массива Кировского рудника. Ось Z — ось высотных отметок массива Кировского рудника. Как видно из приведенной модели (рис. 2) четко выделяется сформированный кластер точек, отвечающих заданным требованиям. При построении

кластера использовался метод ближайших соседей («K-means»), разбивающий множество элементов векторного пространства на заранее известное число кластеров k [8, 9].

Отметим, что на каждой итерации вычисляется центр масс для каждого кластера, полученного на предыдущем шаге, затем векторное пространство разбивается на кластеры вновь в соответствии с тем, какой из новых центров оказался ближе по выбранной метрике.

В данной модели (рис. 3), точки, сгруппированные в левой части рисунка, — это координаты скважин, где расположены датчики деформационного мониторинга, а точки, для которых используется линейный градиент, обозначают энерге-




Рис. 2. Трехмерная модель массива с координатами событий со значением энергии от 50 до 500 кДж
Fig. 2. Three-dimensional model of the rock massif with the coordinates of seismic events with energy value from 50 to 500 kJ




Рис. 3. Трехмерная модель массива с координатами событий с сигнатурой более 15 МДж

Fig. 3. Three-dimensional model of the rock massif with the coordinates of seismic events with energy value above 15 MJ

тические события. Изменение величины интенсивности сейсмического события показано на шкале линейного градиента. На рис. 4 приведены графики деформационного мониторинга, позволяющие определить динамику деформационных процессов в массиве за весь период наблюдения.

Сопоставление данных, полученных в результате моделирования, с данными деформационного мониторинга, позволяет сделать следующие выводы:

1. Визуализация данных сейсмического мониторинга методами машинного обучения позволила установить наличие в массиве двух кластеров сейсмических событий. Факторами, определяющими принадлежность события к кластеру, являются энергия сейсмического события

и расстояние между сейсмическими событиями.

2. В массиве горных пород прослеживается связь между сейсмическими событиями и значениями деформаций. Так, например, деформационные процессы различного характера берут свое начало в одинаковое для всех скважин время: 22 февраля 07:01. При этом, согласно графику сейсмического мониторинга за 22 февраля 2018 г. наиболее крупное по сигнатуре событие в тот день было зафиксировано в 11:40 и составляло 4,2 МДж. Наиболее крупными событиями за отчетный период являются два сейсмических события: 17 февраля в 12:23—34 МДж и 23 февраля в 16:31—17 МДж. После сейсмического события от 23 февраля никаких качественных

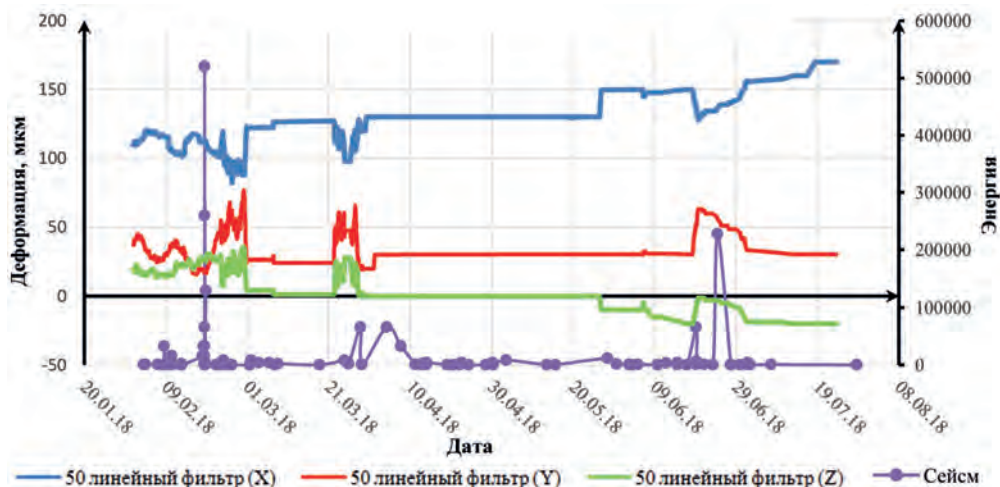


Рис. 4. Результаты мониторинга деформаций по датчику № 6 с учетом сейсмособытий, приуроченных к максимальному росту деформаций

Fig. 4. Results of deformation monitoring using sensor № 5, taking into account the seismic events associated with the maximum increase in deformations

изменений на графиках значений деформации не наблюдается, при этом его сигнатура в 4 раза превышает сигнатуру события от 22 февраля, что дает возможность сделать сразу несколько предположений:

2.1. Поскольку крупные сейсмические события имеют довольно долгий «отклик» в массиве, то одновременное начало различных деформационных процессов в скважинах № 1, 2, 3, 5 от 22 февраля в 07:01 может быть связано с сейсмическим событием от 17 февраля в 12:23.

2.2. Основываясь на полученных в ходе лабораторных испытаний значениях деформаций, можно сделать вывод, что все значения деформации, превышающие 350 мкм, являются показателями возникновения неупругих деформаций в массиве. Таким образом, значения, зафиксированные в 1 и 3 скважинах, свидетельствует о возможности существования таких явлений, как накопление потенциальной энергии, способной реализоваться в виде динамических проявлений горного давления, и разрушение массива в окрестности скважины.

Использование методов машинного обучения для получения математической модели временного ряда деформаций

Для получения функциональной зависимости временного ряда значений деформаций в работе используются данные смещения датчика пятой скважины по оси Z за февраль 2018 г.

Сначала применялось простое экспоненциальное сглаживание. В качестве коэффициента α , отвечающего за сглаживание, применялись значения 0,3 и 0,05. Чем больше значение коэффициента α , тем меньший «вес» отдается предыдущим наблюдениям при построении ряда. Задача: найти такое значение α , при котором удастся соблюсти баланс между точностью предсказанных значений и их структурной связанностью друг с другом. Как видно из графика (рис. 5), использованный метод не дал нужных результатов. При $\alpha = 0,3$ построенный ряд улавливает тренд, но при этом дает большое расхождение между предсказанным и актуальным значениями. Уве-

личение коэффициента α будет означать отказ от связей между наблюдениями при построении модели, что не приемлемо. При $\alpha = 0,05$ линия уровня временного ряда группируется вокруг средневзвешенного значения, что не является объективным отражением процессов в массиве горных пород. Таким образом, следует применить модель двойного экспоненциального сглаживания, известную как модель Хольта [10].

Поскольку в данной модели поведение временного ряда описывается двумя сглаживающими коэффициентами, то их подбор выполняется с помощью алгоритма градиентного бустинга для уменьшения значения минимума ошибки.

Суть подхода к построению модели — обучение модели начинается на небольшом отрезке временного ряда, от начала до некоторого t , а затем делается прогноз на $t + n$ шагов вперед и считается ошибка. Далее расширяется обучающая выборка до $t + n$ значений и прогнозиру-

ется с $t + n$ до $t + 2 \cdot n$ значений. Так итерационно продолжается движение тестового отрезка ряда до последнего доступного наблюдения. В итоге получим столько выборок, сколько уместится в промежутке между изначальным обучающим отрезком и всей длиной ряда.

Затем на каждом шаге итерационного процесса вычисляется значение функции потерь $\nabla L_{\theta}(\hat{\theta})$. Далее идет обновление приближения параметров

$$\hat{\theta} \leftarrow \hat{\theta} + \hat{\theta}_t = \sum_{i=0}^M \hat{\theta}_i.$$

Если же полученное значение функции потерь выходит за доверительный интервал, то рассматриваемая точка относится к «аномальным».

В ходе итерационного подбора коэффициентов α и β было установлено, что при значениях коэффициентов 0,45 и 0,3 соответственно, временной ряд становится неустойчив к выбросам, и теряется информативность. Были определе-

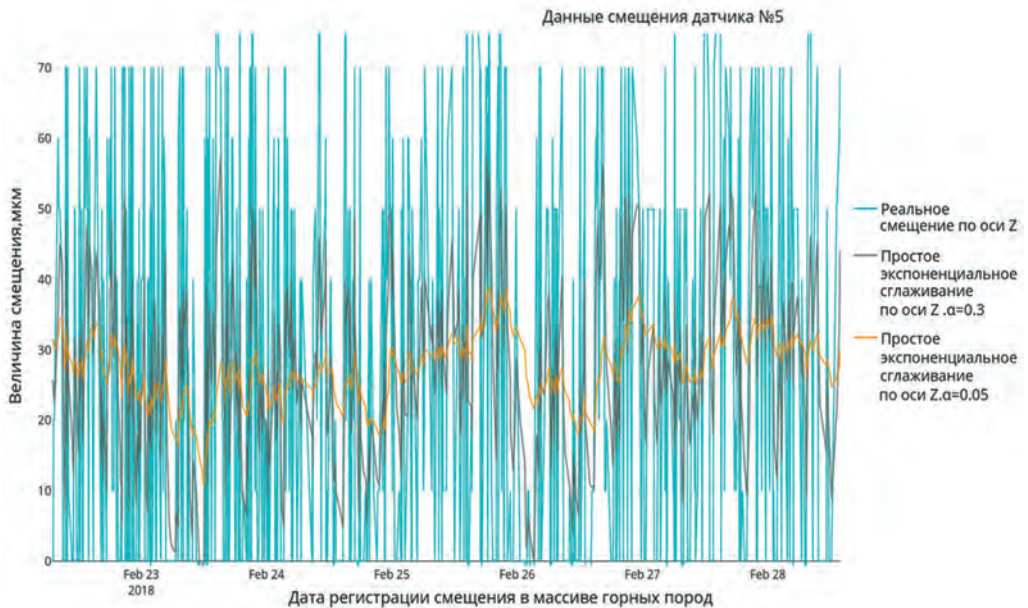


Рис. 5. Простое экспоненциальное сглаживание данных смещения датчика пятой скважины по оси Z за февраль 2018 г.

Fig. 5. Simple exponential smoothing for the deformation data obtained from №5 sensor in Z axis for February 2018

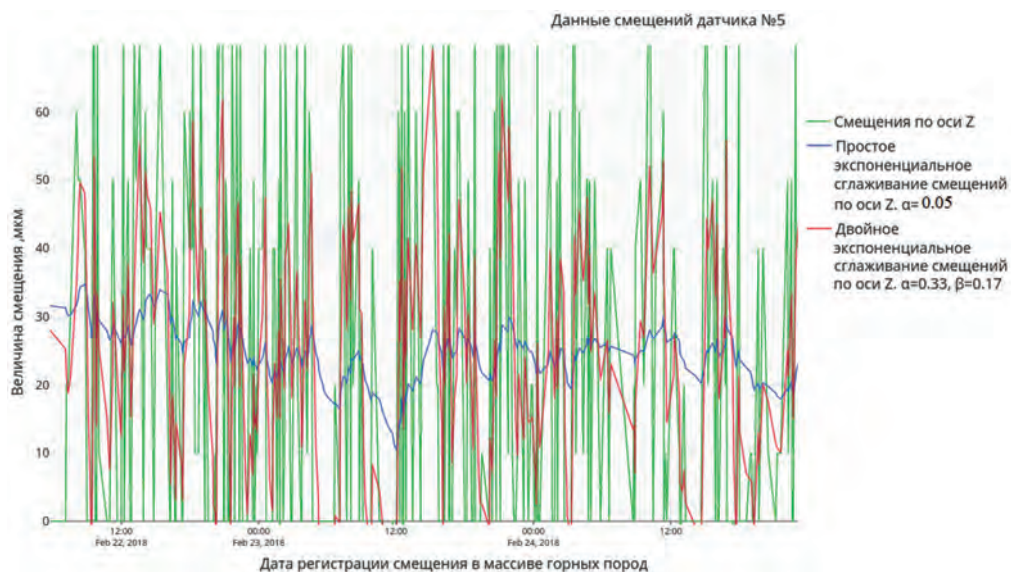


Рис. 6. Сравнение результатов применения алгоритмов простого экспоненциального сглаживания и двойного экспоненциального сглаживания для значений смещения датчика пятой скважины по оси Z за февраль 2018 г. за период с 22.02.2018 по 24.02.2018 гг.

Fig. 6. Comparison of the results of applying the simple exponential smoothing and double exponential smoothing algorithms for the deformation data obtained from №5 sensor in Z axis for February 2018 for the period from 02.22.2018 to 02.02.2018

ны значения коэффициентов $\alpha = 0,33$ и $\beta = 0,17$.

Как видно из графика (рис. 6), полученная модель оказалась устойчива к выбросам и смогла верно предсказать тренд. Но при этом для полученной модели можно выделить относительно большое среднее квадратичное отклонение. Полученная проблема связана с отсутствием «сезонности» временного ряда [11]. Для ее решения требуется проведение измерений в рамках определенных временных промежутков, носящих периодический характер.

СПИСОК ЛИТЕРАТУРЫ

1. Протосеня А. Г., Вербило П. Э. Изучение прочности на сжатие трещиноватого горного массива // Записки Горного института. — 2017. — Т. 223. — С. 51–57.
2. Ridgeway G. The state of boosting // Computing Science and Statistics. 1999, Vol. 31. Pp. 172–181.
3. Мишулина О. А. Статистический анализ и обработка временных рядов. — М.: МИФИ, 2004. — 180 с.
4. Holt Charles C. Forecasting trends and seasonal by exponentially weighted averages // International Journal of Forecasting. January–March 2004. 20 (1): 5–10.

Заключение

Использование методов машинного обучения позволяет обучать и строить математические модели временных рядов, основываясь на данных деформационного мониторинга.

Полученные значения коэффициентов α и β свидетельствуют о том, что построенная математическая модель в достаточной мере отображает связь наблюдений между собой во временном ряду и может быть использована как прогностический признак наступления опасных геодинамических событий.

5. Friedman J.H. Greedy Function Approximation: a Gradient Boosting Machine. Technical Report. Dept. of Statistics, Stanford University, 1999.
6. Mason L., Baxter J., Bartlett P. L., Frean Marcus. Boosting Algorithms as Gradient Descent (PDF) / In S.A. Solla and T.K. Leen and K. Müller. *Advances in Neural Information Processing Systems 12*. MIT Press. 1999. pp. 512–518.
7. Brown R. G., Meyer R.F. The fundamental theorem of exponential smoothing. *Oper. Res*, 1961. Vol. 9. no 5.
8. Muller A., Guido S. *Introduction to Machine Learning with Python: A Guide for Data Scientist*. Moscow: O'Reilly Media, 2017. p. 392.
9. Силен Д., Мейсман А., Али М. *Основы Data Science и Big Data. Python и наука о данных*. — СПб.: Питер, 2017. — 336 с.
10. Brown Robert Goodell *Smoothing Forecasting and Prediction of Discrete Time Series*. Englewood Cliffs, NJ: Prentice-Hall. 1963.
11. Лукашин Ю. П. *Адаптивные методы краткосрочного прогнозирования временных рядов*. — М.: Финансы и статистика, 2003. — 416 с.
12. Подкорытова О. А., Соколов М. В. *Анализ временных рядов: учебное пособие для бакалавриата и магистратуры*. 2-е изд., перераб. и доп. — М.: Изд-во Юрайт, 2018. — 267 с.
13. Box G., Jenkins G., Reinsel G., Ljung G. *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.
14. Aravkin A., Burke J. V. , Ljung L., Lozano A., Pillonetto G. *Generalized kalman smoothing: Modeling and algorithms*. Survey to appear in *Automatica*, 2017.
15. Aravkin A., Abrami A., Kim Y. *Time series using exponential smoothing cells*. *Stat ML*, 2017. **17:13**

REFERENCES

1. Protosenya A. G., Verbilo P. E. Study of compressive strength of fractured rock mass. *Zapiski Gornogo instituta*. 2017. Vol. 223, pp. 51–57. [In Russ].
2. Ridgeway G. The state of boosting. *Computing Science and Statistics*. 1999, Vol. 31. Pp. 172–181.
3. Mishulina O. A. *Statisticheskiiy analiz i obrabotka vremennykh ryadov* [Statistical analysis and processing of time series], Moscow, MIFI, 2004, 180 p.
4. Holt Charles C. Forecasting trends and seasonal by exponentially weighted averages. *International Journal of Forecasting*. January–March 2004. 20 (1): 5–10.
5. Friedman J.H. *Greedy Function Approximation: a Gradient Boosting Machine*. Technical Report. Dept. of Statistics, Stanford University, 1999.
6. Mason L., Baxter J., Bartlett P. L., Frean Marcus. Boosting Algorithms as Gradient Descent (PDF). In S.A. Solla and T.K. Leen and K. Müller. *Advances in Neural Information Processing Systems 12*. MIT Press. 1999. pp. 512–518.
7. Brown R. G., Meyer R.F. *The fundamental theorem of exponential smoothing*. *Oper. Res*, 1961. Vol. 9. no 5.
8. Muller A., Guido S. *Introduction to Machine Learning with Python: A Guide for Data Scientist*. Moscow: O'Reilly Media, 2017. p. 392.
9. Силен Д., Мейсман А., Али М. *Основы Data Science и Big Data. Python и наука о данных* [Data Science and Big Data basics. Python and data science], Saint-Petersburg, Piter, 2017, 336 p.
10. Brown Robert Goodell *Smoothing Forecasting and Prediction of Discrete Time Series*. Englewood Cliffs, NJ: Prentice-Hall. 1963.
11. Lukashin Yu. P. *Adaptivnyye metody kratkosrochnogo prognozirovaniya vremennykh ryadov* [Adaptive methods of short-term time series forecasting], Moscow, Finansy i statistika, 2003, 416 p.
12. Podkorytova O. A., Sokolov M. V. *Analiz vremennykh ryadov: uchebnoe posobie dlya bakalavriata i magistratury*. 2-e izd. [Time-series analysis: textbook for undergraduate and graduate programs. 2nd edition], Moscow, Izd-vo Yurayt, 2018, 267 p.
13. Box G., Jenkins G., Reinsel G., Ljung G. *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.
14. Aravkin A., Burke J.V. , Ljung L., Lozano A., Pillonetto G. *Generalized kalman smoothing: Modeling and algorithms*. Survey to appear in *Automatica*, 2017.
15. Aravkin A., Abrami A., Kim Y. *Time series using exponential smoothing cells*. *Stat ML*, 2017.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Господариков Александр Петрович¹ — д-р техн. наук, профессор,

Морозов Константин Валентинович¹ — канд. техн. наук,

Ревин Илья Евгеньевич¹ — аспирант, revine@inbox.ru,

¹ Санкт-Петербургский горный университет.

Для контактов: Ревин И.Е., e-mail: revine@inbox.ru.

INFORMATION ABOUT THE AUTHORS

A.P. Gospodarikov¹, Dr. Sci. (Eng.), Professor,

K.V. Morozov¹, Cand. Sci. (Eng.),

I.E. Revin¹, Graduate Student, e-mail: revine@4inbox.ru,

¹ Saint-Petersburg Mining University, 199106, Saint-Petersburg, Russia.

Corresponding author: I.E. Revin, e-mail: revine@inbox.ru.



ОТДЕЛЬНЫЕ СТАТЬИ ГОРНОГО ИНФОРМАЦИОННО-АНАЛИТИЧЕСКОГО БЮЛЛЕТЕНЯ (СПЕЦИАЛЬНЫЙ ВЫПУСК)

ВЫБОР И ОБОСНОВАНИЕ ПАРАМЕТРОВ ТЕХНОЛОГИЧЕСКОГО ОБОРУДОВАНИЯ КОМПЛЕКСА ДОБЫЧИ ТОРФЯНОГО СЫРЬЯ ИЗ НАТУРАЛЬНОЙ ЗАЛЕЖИ

(2019, СВ 4, 16 с.)

Худякова Ирина Николаевна¹ — аспирант, e-mail: s165095@pers.spmi.ru,

Вагапова Эльнара Абдуммаевна¹ — аспирант, e-mail: s165072@pers.spmi.ru,

Иванов Сергей Леонидович¹ — д-р техн. наук, профессор, e-mail: Ivanov_SL@pers.spmi.ru,

¹ Санкт-Петербургский горный университет.

Предложена технология добычи и карьерной переработки торфяного сырья без предварительной подготовки месторождения в рамках климатосберегающих технологий и схемные решения комплекса горного оборудования для его осуществления. Представлены пооперационные энергозатраты для схем технологического горного оборудования плавучего комплекса по добыче и переработке торфяного сырья. Дана общая структурная формула комплекса. Получены математические выражения, описывающие выявленные закономерности изменения производительности от мощности приводных двигателей и массовых характеристик горного оборудования комплекса в соответствии с его структурной формулой. Предложен алгоритм выбора основных параметров оборудования комплекса для добычи и переработке торфяного сырья из обводненной залеж.

Ключевые слова: торфяное сырье, структурная схема, структурная формула, комплекс горного оборудования, обводненная залежь.

SELECT ON AND SUBSTANT AT ON OF PARAMETERS OF TECHNOLOG CAL EQU PMENT OF PEAT EXTRACT ON COMPLEX FROM NATURAL DEPOS TS

I.N. Khudyakova¹, Graduate Student, e-mail: s165095@pers.spmi.ru,

E.A. Agapova¹, Graduate Student, e-mail: s165072@pers.spmi.ru,

S.L. Ivanov¹, Dr. Sci. (Eng.), Professor, e-mail: Ivanov_SL@pers.spmi.ru,

¹ Saint-Petersburg mining University, Russia.

The technology of extraction and quarry processing of peat raw materials without preliminary preparation of the Deposit in the framework of climate-saving technologies and schematic solutions of the mining equipment for its implementation. The paper presents the operational energy consumption for the schemes of technological mining equipment floating complex for the extraction and processing of peat raw materials. The General structural formula of the complex is given. Mathematical expressions describing the revealed regularities of performance change from the power of drive motors and mass characteristics of mining equipment of the complex in accordance with its structural formula are obtained. An algorithm for selecting the main parameters of the complex equipment for the extraction and processing of peat raw materials from a watered Deposit is proposed.

Key words: peat materials, structural scheme, structural formula, complex of mining equipment, water reservoir.