

**АЛГОРИТМ ПРОГНОЗИРОВАНИЯ СОСТОЯНИЯ ОБОРУДОВАНИЯ
НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ**

М. Р. САЛИХОВ*, Р. А. ЮРЬЕВА

Университет ИТМО, Санкт-Петербург, Россия
**fanny2man@gmail.com*

Аннотация. Проведен анализ показаний датчиков производственного оборудования и представлена методика агрегации данных для оценки вероятности выхода оборудования из строя. Актуальность исследования обусловлена недостаточным развитием научно-методического аппарата оценивания состояния оборудования на основе больших данных. С целью формирования набора данных, предназначенного для разработки прогностической модели состояния оборудования, сконструирован ряд признаков, характеризующих состояние станка с числовым программным управлением. Практическая значимость исследования обусловлена возможностью включения сформированного набора данных в производственный процесс и использования его для сохранения во времени и в установленных пределах значений параметров оборудования, которые характеризуют его способность выполнять требуемые функции в заданных режимах и при необходимых условиях применения.

Ключевые слова: анализ данных, машинное обучение, нейронные сети, автоматизация производства, LSTM

Ссылка для цитирования: Салихов М. Р., Юрьева Р. А. Алгоритм прогнозирования состояния оборудования на основе машинного обучения // Изв. вузов. Приборостроение. 2022. Т. 65, № 9. С. 648—655. DOI: 10.17586/0021-3454-2022-65-9-648-655.

**ALGORITHM FOR PREDICTING THE STATE OF EQUIPMENT
BASED ON MACHINE LEARNING**

M. R. Salikhov*, R. A. Yurieva

ITMO University, St. Petersburg, Russia
**fanny2man@gmail.com*

Abstract. Analysis of production equipment sensors readings is carried out and a data aggregation technique is presented to assess the probability of equipment failure. The study relevance is due to the insufficient development of the scientific and methodological apparatus for assessing equipment condition based on big data. In order to form a data set intended for development of a predictive model of the equipment state, a number of features characterizing the state of machine with numerical program control are constructed. Practical significance of the study is related with the possibility of including the generated data set in the production process and using it to save the values of equipment parameters in time and within the established limits, which characterize its ability to perform the required functions in the specified modes and under the necessary conditions of use.

Keywords: data analysis, machine learning, neural networks, production automation, LSTM

For citation: Salikhov M. R., Yurieva R. A. Algorithm for predicting the state of equipment based on machine learning. *Journal of Instrument Engineering*. 2022. Vol. 65, N 9. P. 648—655 (in Russian). DOI: 10.17586/0021-3454-2022-65-9-648-655.

Введение. В период эксплуатации производственного оборудования на его состояние влияет ряд случайных факторов. Наибольшее влияние на темпы ухудшения состояния оборудования оказывают такие факторы, как качество обслуживания и ремонта, температура окружающей среды, условия процесса, вибрация. Случайная природа этих факторов приводит к возникновению непредсказуемых изменений технического состояния промышленного оборуду-

дования, элементов его систем, механизмов и в результате к возможному выходу оборудования из строя.

При внедрении на предприятии „умного“ производства требования к надежности оборудования и управлению его обслуживанием постепенно возрастают. Часто возникает необходимость замены компонентов оборудования вследствие истечения срока их эксплуатации, однако на практике не всегда возможно вовремя заменить определенную деталь. Оборудование может быть отремонтировано, если перестающие работать компоненты не обеспечивают необходимые параметры в заданных пределах (технологическая и геометрическая точность, прецессия и т.д.). В этом отношении отказы элементов и параметрические отказы различны. Для повышения рентабельности производства рекомендуется проводить ремонт не при появлении фиксированной неисправности, а заранее, чтобы сократить время простоя оборудования.

Для прогнозирования неисправности промышленного оборудования на основе машинного обучения значительную часть работы занимает подготовка данных. В настоящей статье рассматривается возможность прогнозирования неисправностей оборудования на основе анализа показаний различных датчиков; представлены анализ данных и методика их „очистки“ от „дублирующих“ переменных, определен тип целевой переменной, осуществлен выбор метрики для упрощения последующих вычислений. Полученные результаты могут быть использованы для прогнозирования времени выхода оборудования из строя на основе машинного обучения.

Обзор предметной области. Для решения задачи прогнозирования отказов производственного оборудования было предложено множество методов и моделей. Отличительной характеристикой этих решений является набор входных и выходных данных и форма представления результатов.

Так, в работах [1—6] исследована группа методов, основанных на таких классических методах, как вероятностные методы и методы, базирующиеся на статистическом анализе данных. Перечисленные методы обеспечивают надежное прогнозирование отказов оборудования при различных условиях эксплуатации только при наличии модели генерации отказов, описывающей неисправности или отклонения от нормальной работы на основе данных, относящихся к предыдущим периодам эксплуатации оборудования.

Следующая группа применяемых методов базируется на интеллектуальном исследовании и анализе относительно больших массивов данных [7—11]. Результатом использования таких методов является выявление статистических закономерностей и связей на основе предоставленных массивов данных, что позволяет создавать модели для прогнозирования. Данные методы обеспечивают хорошие результаты для детектирования сбоев и выявления их локальных последствий. Однако в случае когда сбой имеет множественный характер, эти методы не дают приемлемых результатов, что ограничивает их использование в режиме реального времени.

Методология RCM (Reliability-Centered Maintenance) [12] основывается на идее обеспечения надежности критически важных производственных и технических бизнес-процессов. Иными словами, предполагается ранжирование агрегатов оборудования, остановка которых не позволит произвести продукцию либо нарушит ритмичность работы агрегатов и узлов, что не приведет к негативным последствиям. Основной проблемой являются операции с большими объемами данных, что в итоге невозможно без создания автоматизированной системы, содержащей характеристики и историю ремонтов оборудования.

Перспективными в области прогнозирования отказов представляются методы, базирующиеся на машинном обучении [13—18]. Данные методы применяются для создания моделей прогнозирования, построение которых основывается на ретроспективных и фактических данных, полученных в режиме реального времени от измерительных устройств. Благодаря обучению адаптация параметров модели прогнозирования происходит быстро, что

позволяет устанавливать новые сроки проведения плановых работ по ремонту оборудования. Таким образом, минимизируется, в значительной степени, время простоя оборудования. Ситуации, в которых отмечается ограниченное количество данных об отказах, являются существенным недостатком данных методов.

Анализ методов и программных средств прогнозирования отказов оборудования показывает, что имеющиеся методы и программное обеспечение не позволяют в полной мере решить задачу прогнозирования отказов в условиях малого количества неисправностей, больших объемов данных, изменяющихся режимов работы оборудования и в случае множественных отказов.

Реализация алгоритма прогнозирования. С целью формирования набора данных, предназначенного для разработки прогностической модели состояния оборудования (станка), было осуществлено конструирование признаков, характеризующих его состояние. Была проведена серия экспериментов по механической обработке деталей — восковых блоков размером $50 \times 50 \times 45$ мм — на фрезерном станке с ЧПУ на испытательном стенде. В каждом эксперименте получалась готовая восковая деталь с буквой „S“, вырезанной на верхней грани.

Подготовка данных. Общие данные (табл. 1) по каждому из 18 экспериментов приведены в тестовом наборе данных и содержат, в том числе, скорость подачи детали (V) и давление зажима (P), по результатам обработки деталей определялось изменение состояния инструментов, также отраженное в таблице (новые и изношенные).

Таблица 1

Номер эксперимента	V , мм/с	P , Па	Состояние инструмента
1	6	4,0	Изношенный
2	20	4,0	Изношенный
3	6	3,0	Изношенный
4	6	2,5	Изношенный
5	20	3,0	Изношенный

По результатам экспериментов были собраны данные временных рядов с частотой дискретизации 100 мс, отдельно представленные в файлах. Каждый файл содержит данные измерений, произведенных четырьмя двигателями на станке с ЧПУ (оси X , Y , Z и шпиндель S).

Признаки, характеризующие состояние станка, представлены в табл. 2.

Таблица 2

Наименование признака	Обозначение признака	Описание признака
Actual Position	X_d, Y_d, Z_d, S_d	Фактическое положение детали, мм
Actual Velocity	V_x, V_y, V_z, V_s	Фактическая скорость детали, мм/с
Actual Acceleration	a_x, a_y, a_z, a_s	Фактическое ускорение детали, м/с ²
Command Position	$X_{d0}, Y_{d0}, Z_{d0}, S_{d0}$	Исходное положение детали, мм
Command Velocity	$V_{x0}, V_{y0}, V_{z0}, V_{s0}$	Исходная скорость детали, мм/с
Command Acceleration	$a_{x0}, a_{y0}, a_{z0}, a_{s0}$	Исходное ускорение детали, м/с ²
Current Feedback	$I_{обр,x}, I_{обр,y}, I_{обр,z}, I_{обр,s}$	Обратная связь по току, А
DC Bus Voltage	$U_{ш,x}, U_{ш,y}, U_{ш,z}, U_{ш,s}$	Напряжение шины постоянного тока, В
Output Current	$I_{в,x}, I_{в,y}, I_{в,z}, I_{в,s}$	Выходной ток, А
Output Voltage	$U_{в,x}, U_{в,y}, U_{в,z}, U_{в,s}$	Выходное напряжение, В
Output Power	$P_{в,x}, P_{в,y}, P_{в,z}, P_{в,s}$	Мощность на выходе, кВт

При обработке результатов был произведен поиск нетипичных данных (выбросов). Для примера был взят признак Actual Velocity по оси X (см. табл. 2) — V_x (рис. 1, а, б). На графиках продемонстрированы значения без удаления выбросов.

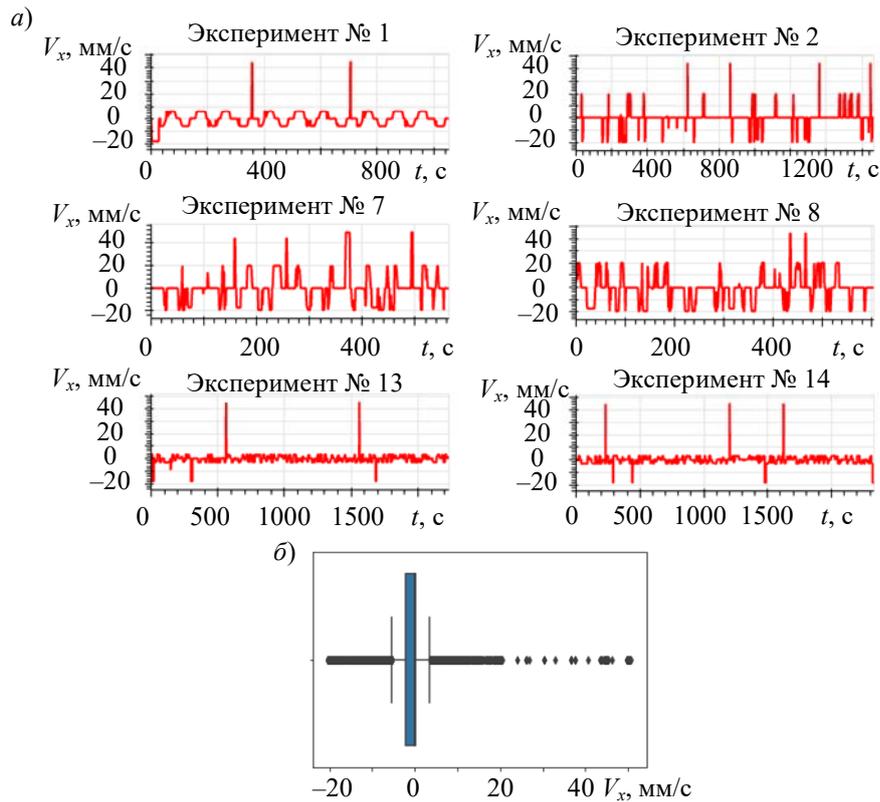


Рис. 1

Далее была проведена „очистка“ данных (data cleaning) от выбросов (рис. 2, а, б). Как можно понять из графиков, при удалении выбросов ничего конструктивного не происходит, выбросы служат некоторым показателем нестандартной работы оборудования.

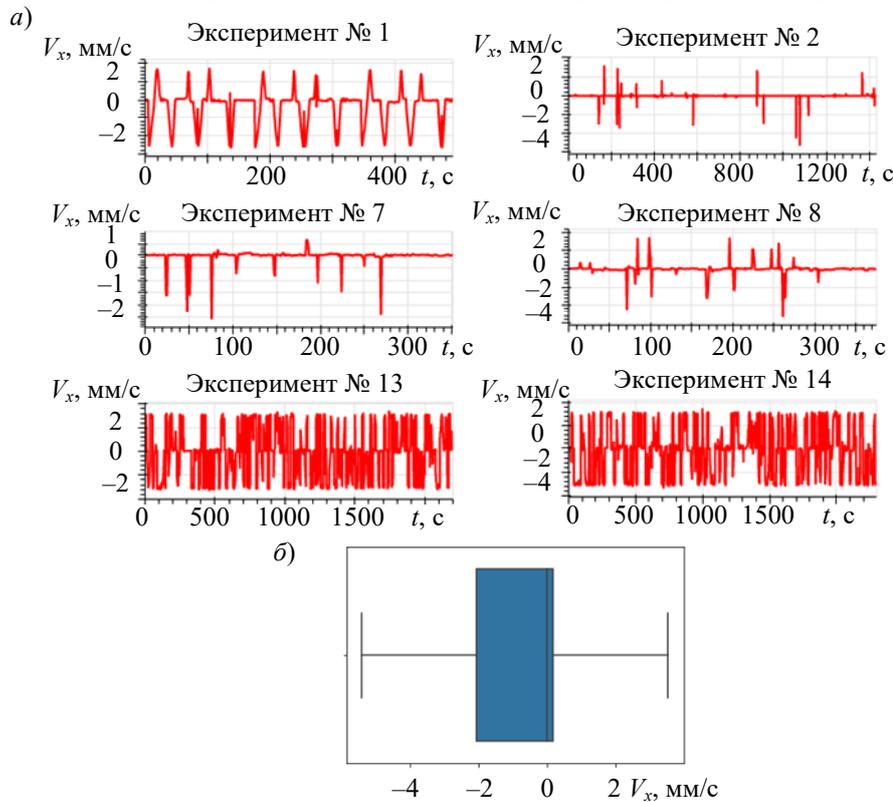


Рис. 2

Если признак характеризуется множеством показателей с одинаковыми значениями (неинформативный признак), он не несет полезной информации и исключается из набора данных. Такой вариант продемонстрирован фрагментом программы.

Z1 Исходное Ускорение: 99.46814%	Z1 Обратная Связь По Току: 100.00000%	Z1 Выходной Ток: 100.00000%
0.000000 21133	0.0 21246	0.0 21246
1000.000000 41	Z1 Напряжение Шины Постоянного Тока: 100.00000%	Z1 Выходное Напряжение: 100.00000%
-1000.000000 35	0.0 21246	0.0 21246
-875.000000 7		
-500.000000 5		

Матрица корреляций. Для выявления коррелирующих признаков была построена матрица корреляций (рис. 3, а, обозначения — согласно принятым в табл. 2). Анализ данной матрицы показывает, что некоторые признаки не несут никакой конструктивной информации и могут быть удалены (рис. 3, б).

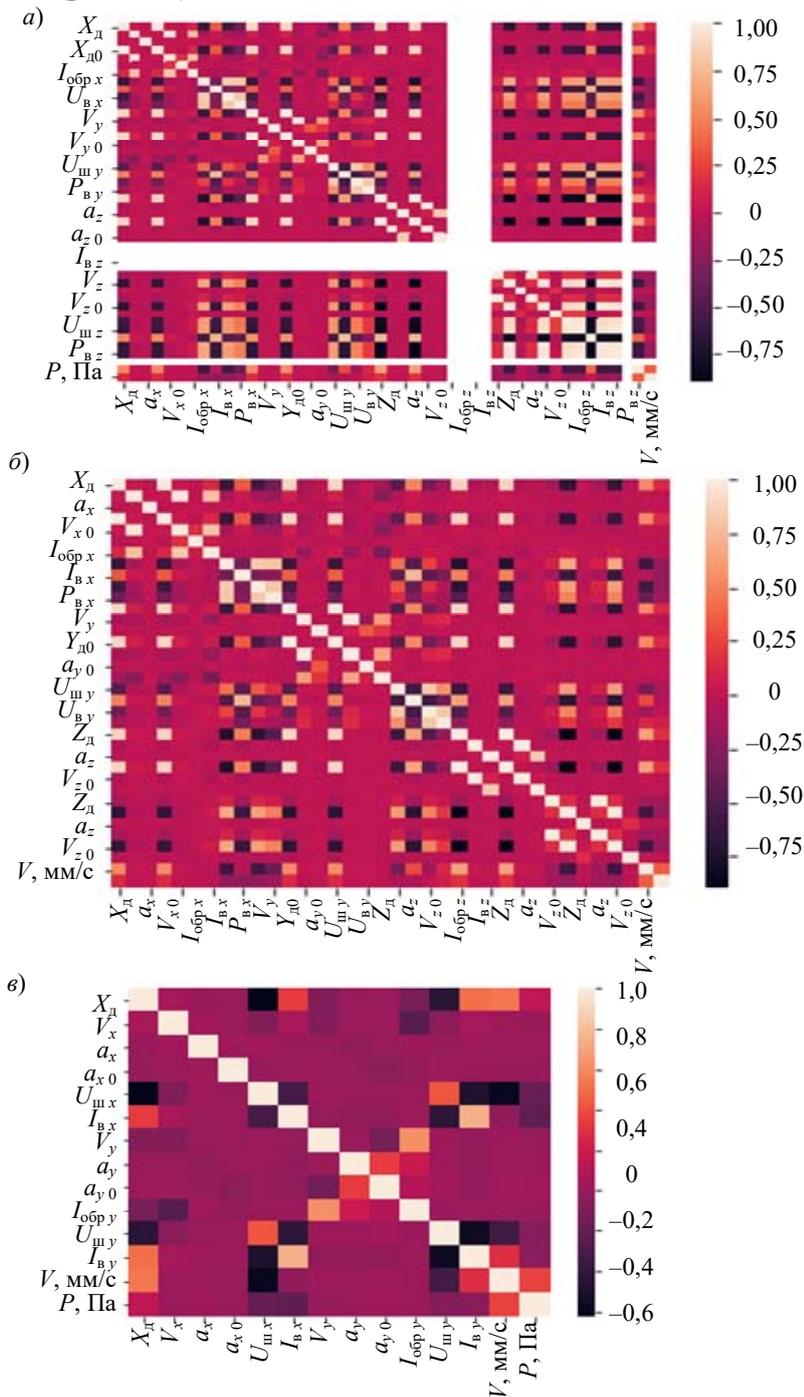


Рис. 3

Удаление коррелирующих признаков. Для оценки силы корреляционной связи, как правило, используются общепринятые критерии, согласно которым абсолютные значения коэффициента корреляции $r_{xy} < 0,4$ свидетельствуют о слабой связи, значения r_{xy} от 0,4 до 0,8 — о связи средней силы, значения $r_{xy} > 0,8$ — о сильной связи. Для удаления коррелирующих признаков был проведен отбор признаков, коэффициент корреляции которых больше 0,8 (рис. 3, в). Коррелирующими оказались такие признаки, как ускорение, напряжение, сила тока, скорость. При изменении одного признака следует изменение другого. Например, с увеличением силы тока, увеличивается и напряжение.

Значимость признаков. После произведенной „очистки“ данных были проведены эксперименты по расчету значимости признака, т.е. признака, оказывающего наибольшее влияние на отказ оборудования.

Для проведения эксперимента, исходя из целей задачи, были выбраны следующие алгоритмы машинного обучения:

- Random Forest Regressor (RFR);
- Gradient Busting Classifier (GBC);
- Gradient Busting Regressor (GBR).

На рис. 4, а—в представлены диаграммы, отражающие значимость признаков согласно указанным алгоритмам. Расчет значимости признаков был проведен без применения быстрого преобразования Фурье (БПФ).

Результаты расчета значимости признаков после применения БПФ представлены на рис. 5, а—в.

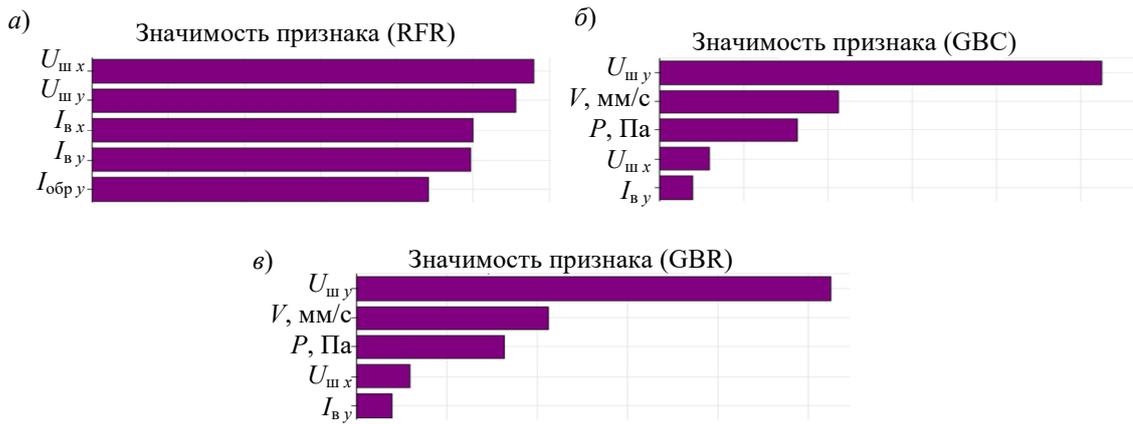


Рис. 4



Рис. 5

На основе данных расчета значимости признаков, влияющих на износ режущего инструмента, получено, что такие показатели, как сила тока и напряжение, оказывают наиболее значимое влияние на износ инструмента.

Алгоритм LSTM. Для реализации алгоритма LSTM (Long Short-Term Memory) в качестве входной информации использовался набор данных, содержащий ряд показаний одного из значащих признаков. После этого была проведена настройка модели, а именно выбор оптимизатора модели и метода оценивания ошибки.

Результат работы алгоритма — набор данных, содержащий спрогнозированные значения признака.

Заключение. Основополагающий принцип прогнозирования состояния станка с ЧПУ — использование предыдущих статистических данных. Информация о поведении станка в прошлом является базой для прогнозирования изменения его состояния в будущем. В рамках исследования проанализированы параметры, влияющие на прогнозирование состояния станка в следующий момент времени. По результатам прогнозирования можно количественно определить вероятность выхода оборудования из строя. Предложенный подход связан с исследованием рядов значений параметров оборудования и выявлением временных зависимостей показателей.

Для решения этой задачи могут быть использованы детерминированные и вероятностные модели, аппарат математического программирования, теория информации, теория статистических решений. Перспективным направлением исследований представляется проверка гипотезы о возможности прогнозирования отказов оборудования методами рекуррентных нейронных сетей.

СПИСОК ЛИТЕРАТУРЫ

1. Седуш В. Я., Ченцов Н. А., Ченцова Н. С. Прогнозирование сроков отказа металлургического оборудования // Металлургическая и горнорудная промышленность. 1994. № 3. С. 75—77.
2. Антонов А. В. Вероятностные методы оценки остаточной наработки восстанавливаемых элементов ЯЭУ в условиях ограниченности исходных данных // Ядерная физика и инжиниринг. 2011. Т. 2, № 5. С. 421—424.
3. Антонов А. В. Методика статистического анализа данных об отказах оборудования АЭС в условиях неоднородного потока событий // Изв. вузов. Ядерная энергетика. 2016. № 3. С. 20—29.
4. Перехвост В. С. Прогнозирование параметрических отказов и особенность случайных процессов старения технических систем // Научные труды КубГТУ. 2014. № 3. С. 38—44.
5. Javed K. State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels // Mechanical Systems and Signal Processing. 2017. Vol. 94, N 9. P. 214—236.
6. Gorjian N. Remaining usefulness of prediction of rotating equipment using covariate-based hazard models – Industry applications // Australian Journal of Mechanical Engineering. 2017. Vol. 15, N 1. P. 36—45.
7. Pitsyk V. V. Probabilistic Prediction of Residual Operating Life of Measurement Equipment Using Results of Parametric Monitoring // Measurement Techniques. 2016. Vol. 59, N 3. P. 216—221.
8. Чугреев В. Л., Баданин Д. А. Использование прогнозной аналитики в информационно-аналитических системах поддержки принятия решений // Молодой ученый. 2016. № 6. С. 49—52.
9. Боровиков С. М., ИТ-система прогнозирования надёжности сложных электронных систем методом анализа дерева отказов // Информационные системы и технологии: управление и безопасность. 2013. № 2. С. 140—144.
10. Mangalova M. S. Dysfunctional components prediction using cubic smoothing splines // Молодежь. Общество. Современная наука, техника и инновации. 2014. № 13. С. 198—199.
11. Лунатов М. Первый в России комплекс предиктивной аналитики для энергетического и промышленного оборудования // Экспозиция Нефть Газ. 2016. № 3 (49). С. 82—83.

12. Гаврилюк Е. А. Прогнозирование отказов систем автоматического управления газоперекачивающими агрегатами на основе индекса технического состояния и степени риска // *Фундаментальные исследования*. 2015. № 7—2. С. 309—313.
13. <https://toir.pro/mod/book/view.php?id=470&chapterid=370>
14. Зиберт А. О. Применения алгоритмов машинного обучения для повышения эффективности использования горной техники // *Universum: технические науки (Электронный науч. журн.)*. 2016. № 2 (24).
15. Цикора М. Применение гибридного метода машинного обучения для описания и непрерывной оценки уровня метановой опасности в горной выработке // *Физико-технические проблемы разработки полезных ископаемых*. 2011. № 4. С. 95—107.
16. Уткин Н. Н. Использование методов машинного обучения для виброакустического диагностирования динамической системы шлифовальных станков // *Вестн. Саратов. гос. техн. ун-та*. 2011. Т. 2, № 2 (56). С. 271—275.
17. Wang Z. Failure prediction using machine learning and time series in optical network // *Optics Express*. 2017. Vol. 25, N 8. P. 18553—18565.
18. Wu W. A quantum multi-agent based neural network model for failure prediction // *J. of Systems Science and Systems Engineering*. 2016. Vol. 25, N 2. P. 210—228.

Сведения об авторах

- Максим Русланович Салихов** — студент; Университет ИТМО, факультет систем управления и робототехники; E-mail: fanny2man@gmail.com
- Радда Алексеевна Юрьева** — канд. техн. наук, доцент; Университет ИТМО, факультет систем управления и робототехники; E-mail: raddaiureva@itmo.ru

Поступила в редакцию 23.05.2022; одобрена после рецензирования 18.06.2022; принята к публикации 30.07.2022.

REFERENCES

1. Sedush V.Ya., Chentsov N.A., Chentsova N.S. *Metallurgicheskaya i gornorudnaya promyshlennost'*, 1994, no. 3, pp. 75–77. (in Russ.)
2. Sokolov S.V., Antonov A.V., Chepurko V.A. *Nuclear Physics and Engineering*, 2011, no. 5(2), pp. 421–424, DOI: 10.1134/S2079562911050058
3. Antonov A.V., Chepurko V.A. *Izvestiya vuzov. Yadernaya Energetika*, 2016, no. 3, pp. 20–29. (in Russ.)
4. Perehvosht V.S. *Scientific Works of the Kuban State Technological University*, 2014, no. 3, pp. 38–44. (in Russ.)
5. Javed K. *Mechanical Systems and Signal Processing*, 2017, no. 9(94), pp. 214–236.
6. Gorjian N. *Australian Journal of Mechanical Engineering*, 2017, no. 1(15), pp. 36–45.
7. Pitsyk V.V. *Measurement Techniques*, 2016, no. 3(59), pp. 216–221.
8. Chugreev V.L., Badanin D.A. *Molodoy uchenyy (Young Scientist)*, 2016, no. 6, pp. 49–52. (in Russ.)
9. Borovikov S.M. *Information Systems and Technologies: Management and Security*, 2013, no. 2, pp. 140–144. (in Russ.)
10. Mangalova M.S. *Molodezh'. Obshchestvo. Sovremennaya nauka, tekhnika i innovatsii*, Krasnoyarsk, 2014, no. 13, pp. 198–199. (in Russ.)
11. Lipatov M. *Exposition Oil & Gas Magazine*, 2016, no. 3(49), pp. 82–83. (in Russ.)
12. Gavrilyuk E.A. *Fundamental Research*, 2015, no. 7-2, pp. 309–313. (in Russ.)
13. <https://toir.pro/mod/book/view.php?id=470&chapterid=370>
14. Zibert A.O. *Universum*, 2016, no. 2(24). (in Russ.)
15. Tsikora M. *Physical and Technical Problems of Mineral Development*, 2011, no. 4, pp. 95–107. (in Russ.)
16. Utkin N.N. *Bulletin of the Saratov State Technical University*, 2011, no. 2(2), pp. 271–275. (in Russ.)
17. Wang Z. *Optics Express*, 2017, no. 8(25), pp. 18553–18565.
18. Wu W. *Journal of Systems Science and Systems Engineering*, 2016, no. 2(25), pp. 210–228.

Data on authors

- Maxim R. Salikhov** — Student; ITMO University, Faculty of Control Systems and Robotics; E-mail: fanny2man@gmail.com
- Radda A. Yurieva** — PhD, Associate Professor; ITMO University, Faculty of Control Systems and Robotics; E-mail: raddaiureva@itmo.ru

Received 23.05.2022; approved after reviewing 18.06.2022; accepted for publication 30.07.2022.